



Universidad Carlos III Madrid

Escuela Politécnica Superior

Ingeniería Informática

Proyecto de fin de carrera

Diseño de Redes de Radio mediante la aplicación de Algoritmos Bioinspirados

Autor: Patricia Rosalía Torpedo Moreno

Tutor: Pedro Isasi Viñuela

Co-director: David Quintana Montero

Fecha: 15 de Enero de 2010

Agradecimientos

A todos aquellos que me han ayudado a lo largo de la carrera, que no han dudado de mí ni por un solo momento y de los que he recibido apoyo constante.

A mis padres que siempre han estado ahí para todo lo que he necesitado, y que han creído en mí cuando yo he dudado.

A mis abuelos que siempre han tenido una irracional fe en mí.

A ti, por estar conmigo durante todos estos años y aguantarme mis más y mis menos, por quererme y apoyarme en todos los momentos.

Y por supuesto a mi “más que compañero” durante estos años de carrera. Sin ti no hubiese sido lo mismo, te debo mucho de lo que he conseguido en la universidad, y no solo me refiero a tu ayuda en la innumerable cantidad de prácticas que hemos hecho juntos.

Os lo agradezco a todos, cada uno de vosotros me habéis ayudado a conseguir lo que tengo hoy.

Índice

Agradecimientos.....	5
Índice	7
Índice de Ilustraciones	11
Índice de Tablas	13
Índice de Gráficos	15
Capítulo 1. Estado del Arte	17
1.1. Introducción.....	17
1.2. Descripción del Problema RND.	19
1.3. Descripción del Dominio OPLINK.....	23
1.4. Distintos estudios realizados para la resolución del problema RND.....	25
1.4.1. Cellular Radio Network Planning	25
1.4.2. Field strength prediction by ray-tracing for adaptive base station positioning in mobile communication network	27
1.4.3. ICEPT – An Integrated Cellular Network Planning Tool.	28
1.4.4. Genetic Approach to Radio Network Optimization for Mobile Systems.	30
1.4.5. A Multiobjective Genetic Algorithm for Radio Network Optimization.	31
1.4.6. Applying Data Mining Methods for Cellular Radio Network Planning.	31
1.4.7. Radio network design using coarsegrained parallel genetic algorithms with different neighbor topology.	32
1.4.8. Evolutionary Algorithms for Optimal Placement of Antennae in Radio Network Design.	33

1.4.9. A Differential Evolution Based Algorithm to Optimize the Radio Network Design Problem.	33
1.4.10. Using Omnidirectional BTS and Different Evolutionary Approaches to Solve the RND Problem.	34
1.4.11. Optimal Antenna Placement Using a New Multi-Objective CHC Algorithm.	35
1.4.12. Desktop Grid Computing with BOINC and its use for Solving the RND Telecommunication Problem.	36
Capítulo 2. Objetivos.....	39
2.1 Introducción.....	39
2.2 Aproximaciones Iniciales	40
2.3 Escenario Concreto del Proyecto.....	46
Capítulo 3. Análisis y Diseño de la Aplicación	49
3.1 Estudio y Análisis del Problema.....	49
3.2 Diseño de la Aplicación	50
3.2.1 Diseño Arquitectónico General.....	50
3.2.2 Información Ficheros.....	54
3.2.3 Diseño Interfaz de Usuario.	55
Capítulo 4. Algoritmos Empleados	59
4.1 Teoría General Algoritmos Genéticos.....	59
4.2 Descripción Algoritmos Genéticos Desarrollados.....	67
4.3 Teoría Optimización con Colonia de Hormigas.	75
4.4 Descripción Algoritmo de Colonias de Hormigas Desarrollado.	79
4.5 Teoría de Clustering.....	87

4.6 Descripción Algoritmo de Colonias de Hormigas con Clustering Desarrollado.	90
Capítulo 5. Resultados y Análisis.....	95
5.1 Resultados y Análisis del Algoritmo Genético.....	95
5.2 Resultados y Análisis del Algoritmo de Colonias de Hormigas Escogiendo Mejor Fitness de la Solución.	108
5.3 Resultados y Análisis del Algoritmo de Colonias de Hormigas Original.	129
5.4 Resultados y Análisis del Algoritmo de Colonias de Hormigas con Clustering.	142
Capítulo 6. Conclusiones	155
Capítulo 7. Líneas Futuras.....	165
Anexo I: Conjunto de Pruebas y Resultados Completo	167
Bibliografía	175

Índice de Ilustraciones

ILUSTRACIÓN 1: EJEMPLO REPRESENTATIVO DISCRETIZACIÓN DEL ÁREA DE TRABAJO	20
ILUSTRACIÓN 2: A) ANTENA CUADRADA Y B) ANTENA CIRCULAR U OMNIDIRECCIONAL.	21
ILUSTRACIÓN 3: REPRESENTACIÓN REJILLA CON A) ANTENAS CUADRADAS Y B) CIRCULARES.	21
ILUSTRACIÓN 4: EJEMPLO DE TRES ANTENAS EN LA REJILLA Y SU ÁREA DE COBERTURA, ASÍ COMO A LAS CELDAS QUE PROPORCIONAN COBERTURA.	22
ILUSTRACIÓN 5: MAPA DE MÁLAGA, ESPAÑA.....	23
ILUSTRACIÓN 6: ESQUEMA ENFOQUE ANALÍTICO.	26
ILUSTRACIÓN 7: (A) DATOS GEOGRÁFICOS Y DEMOGRÁFICOS Y (B) DISTRIBUCIÓN DE NODOS DE DEMANDA.	28
ILUSTRACIÓN 8: ILUSTRACIÓN DEL PROCESO DE GENERACIÓN DE LOS NODOS DEMANDA.	29
ILUSTRACIÓN 9: ORGANIZACIÓN ENFOQUE INTEGRADO.	29
ILUSTRACIÓN 10: REPRESENTACIÓN GRÁFICA RESULTADOS ESCENARIO RELAJADO CON FITNESS ORIGINAL.	43
ILUSTRACIÓN 11: REPRESENTACIÓN GRÁFICA RESULTADOS ESCENARIO RELAJADO CON FITNESS NUEVO	45
ILUSTRACIÓN 12: DIAGRAMA DISEÑO GENERAL	51
ILUSTRACIÓN 13: DIAGRAMA EJEMPLO FUNCIONAMIENTO CON “PATRÓN STRATEGY”	53
ILUSTRACIÓN 14: INTERFAZ DE USUARIO DE LA APLICACIÓN.....	55
ILUSTRACIÓN 15: TRES PESTAÑAS DE CONFIGURACIÓN DE LOS ALGORITMOS EN LA IU.	56
ILUSTRACIÓN 16: EJEMPLO REPRESENTACIÓN GRÁFICA Y TEXTUAL EN INTERFAZ DE USUARIO.....	57
ILUSTRACIÓN 17: EJEMPLO ILUSTRATIVO DEL FUNCIONAMIENTO DEL OPERADOR DE SELECCIÓN POR RULETA.....	63
ILUSTRACIÓN 18: EJEMPLO ILUSTRATIVO VARIANTE OPERADOR DE SELECCIÓN POR RULETA SIN RANKING.	64
ILUSTRACIÓN 19: EJEMPLO ILUSTRATIVO VARIANTE OPERADOR DE SELECCIÓN POR RULETA CON RANKING.	64
ILUSTRACIÓN 20: EJEMPLO CRUCE SIMPLE.	65
ILUSTRACIÓN 21: EJEMPLO CRUCE MULTIPUNTO.	65
ILUSTRACIÓN 22: EJEMPLO CRUCE UNIFORME.	66
ILUSTRACIÓN 23: EJEMPLO OPERADOR MUTACIÓN.	66
ILUSTRACIÓN 24: FASES DEL AG.	68
ILUSTRACIÓN 25: EJEMPLO REPRESENTACIÓN INDIVIDUO EN AG.	69
ILUSTRACIÓN 26: COMPORTAMIENTO ADAPTATIVO DE LAS HORMIGAS.	76
ILUSTRACIÓN 27: ESQUEMA DE LAS FASES DEL ALGORITMO DE COLONIAS DE HORMIGAS.....	86
ILUSTRACIÓN 28: DISTRIBUCIÓN CON 70 CLUSTER DEL ALGORITMO SIMPLE K-MEDIAS EN EL ESCENARIO DE MÁLAGA.	91
ILUSTRACIÓN 29: MEJOR RESULTADO DEL AG.	102
ILUSTRACIÓN 30: MEJOR RESULTADO DEL ALGORITMO DE COLONIAS DE HORMIGAS MODIFICADO CON COBERTURA COMO UMBRAL.....	114
ILUSTRACIÓN 31: MEJOR RESULTADO DEL ALGORITMO DE COLONIAS DE HORMIGAS MODIFICADO CON ANTENAS COMO UMBRAL.....	123

ILUSTRACIÓN 32: MEJOR RESULTADO DEL ALGORITMO DE COLONIAS DE HORMIGAS ORIGINAL CON ANTENAS COMO UMBRAL.	133
ILUSTRACIÓN 33: MEJOR RESULTADO DEL ALGORITMO DE COLONIAS DE HORMIGAS ORIGINAL CON PORCENTAJE DE COBERTURA COMO UMBRAL.....	139
ILUSTRACIÓN 34: MEJOR RESULTADO DEL ALGORITMO DE COLONIAS DE HORMIGAS CON CLUSTERING.	151

Índice de Tablas

TABLA 1: TABLA DE RESULTADOS DEL ALGORITMO GENÉTICO CON FITNESS ORIGINAL EN EL ESCENARIO RELAJADO. .	42
TABLA 2: TABLA DE RESULTADOS DEL ALGORITMO GENÉTICO CON FITNESS ORIGINAL EN EL ESCENARIO RELAJADO. .	45
TABLA 3: RESULTADOS DE LAS PRUEBAS REALIZADAS PARA EL ANÁLISIS DE LA MEJOR FUNCIÓN DE FITNESS A APLICAR.	96
TABLA 4: PRUEBAS Nº ANTENAS INICIALIZACIÓN AG	97
TABLA 5: RESULTADOS PRUEBAS PARA TIPO DE CREACIÓN POBLACIÓN INICIAL.	98
TABLA 6: RESULTADOS PRUEBAS PARA OPERADOR DE SELECCIÓN.	99
TABLA 7: RESULTADOS PRUEBAS PARA OPERADOR DE CRUCE.....	100
TABLA 8: RESULTADOS PRUEBAS PARA VALORES MÁXIMO Y MÍNIMO DE MUTACIÓN.....	100
TABLA 9: RESULTADOS AG CON LA CONFIGURACIÓN ÓPTIMA.	103
TABLA 10: RESULTADOS PRUEBAS PARA EL ESTUDIO DE NÚMERO DE EVALUACIONES MÁXIMAS PARA EL ALGORITMO DE COLONIAS DE HORMIGAS MODIFICADO.	109
TABLA 11: RESULTADOS PRUEBAS PARA ANÁLISIS DE LOS VALORES DE LAS CONSTANTES DE ACTUALIZACIÓN DE FEROMONA PARA EL ALGORITMO DE COLONIAS DE HORMIGAS ESCOGIENDO SUBSOLUCIÓN DE MAYOR FITNESS.	110
TABLA 12: RESULTADOS PRUEBAS DE ANÁLISIS DEL MEJOR VALOR DE UMBRAL DE COBERTURA PARA EL ALGORITMO DE COLONIAS DE HORMIGAS ESCOGIENDO LA SUBSOLUCIÓN DE MAYOR FITNESS.	112
TABLA 13: RESULTADOS MEJOR CONFIGURACIÓN ALGORITMO COLONIAS DE HORMIGAS ESCOGIENDO SUBSOLUCIÓN CON MAYOR VALOR DE FITNESS Y PORCENTAJE DE COBERTURA COMO UMBRAL.	113
TABLA 14: RESULTADOS PRUEBAS DE ANÁLISIS DEL MEJOR VALOR DE UMBRAL DE ANTENAS PARA EL ALGORITMO DE COLONIAS DE HORMIGAS ESCOGIENDO LA SUBSOLUCIÓN DE MAYOR FITNESS.	120
TABLA 15: RESULTADOS MEJOR CONFIGURACIÓN ALGORITMO COLONIAS DE HORMIGAS ESCOGIENDO SUBSOLUCIÓN CON MAYOR VALOR DE FITNESS Y ANTENAS COMO UMBRAL.	122
TABLA 16: RESULTADOS DEL ANÁLISIS DE LOS VALORES DE LAS CONSTANTES DE ACTUALIZACIÓN DE FEROMONA PARA EL ALGORITMO DE COLONIAS DE HORMIGAS ORIGINAL.....	130
TABLA 17: RESULTADOS DE LAS PRUEBAS DE ANÁLISIS DEL MEJOR VALOR DE UMBRAL DE ANTENAS POR EL ALGORITMO DE COLONIAS DE HORMIGAS ORIGINAL.....	132
TABLA 18: RESULTADO DE LA MEJOR CONFIGURACIÓN DEL ALGORITMO DE COLONIAS DE HORMIGAS ORIGINAL CON MAYOR VALOR DE FITNESS Y ANTENAS COMO UMBRAL.	133
TABLA 19: RESULTADOS DE LAS PRUEBAS DE ANÁLISIS DEL MEJOR VALOR DE UMBRAL DE PORCENTAJE DE COBERTURA PARA EL ALGORITMO DE COLONIAS DE HORMIGAS ORIGINAL.	136
TABLA 20: RESULTADO DE LA MEJOR CONFIGURACIÓN PARA EL ALGORITMO DE COLONIAS DE HORMIGAS ORIGINAL CON MAYOR VALOR DE FITNESS Y PORCENTAJE DE COBERTURA COMO UMBRAL.	138
TABLA 21: RESULTADOS OBTENIDOS PARA EL ESTUDIO DEL Nº MÁXIMO DE EVALUACIONES PARA EL ALGORITMO DE COLONIAS DE HORMIGAS CON CLUSTERING.	143
TABLA 22: RESULTADOS OBTENIDOS DE LAS PRUEBAS PARA EL ANÁLISIS DE LOS VALORES DE Γ , A Y B PARA EL ALGORITMO DE COLONIAS DE HORMIGAS CON CLUSTERING.	144

TABLA 23: RESULTADOS PRUEBAS DEL ESTUDIO DE LOS MÉTODOS DE CLUSTERING Y NÚMERO DE CLUSTER PARA EL ALGORITMO DE COLONIAS DE HORMIGAS CON CLUSTERING.	146
TABLA 24: RESULTADOS DEL CONJUNTO DE 10 EJECUCIONES CON LA MEJOR CONFIGURACIÓN PARA EL ALGORITMO DE COLONIAS DE HORMIGAS CON CLUSTERING.	147
TABLA 25: CONJUNTO TOTAL DE PRUEBAS REALIZADAS PARA EL AG.....	168
TABLA 26: CONJUNTO TOTAL DE PRUEBAS REALIZADAS PARA EL ALGORITMO DE COLONIAS DE HORMIGAS MODIFICADO.	170
TABLA 27: CONJUNTO TOTAL DE PRUEBAS REALIZADAS PARA EL ALGORITMO DE COLONIAS DE HORMIGAS ORIGINAL.	172
TABLA 28: CONJUNTO TOTAL DE PRUEBAS REALIZADAS PARA EL ALGORITMO DE COLONIAS DE HORMIGAS CON CLUSTERING.	174

Índice de Gráficos

GRÁFICO 1: GRÁFICO Nº ANTENAS SOLUCIÓN FINAL EN BASE A Nº ANTENAS INICIALIZACIÓN.....	97
GRÁFICO 2: Nº DE ANTENAS RESULTADOS AG CON LA CONFIGURACIÓN ÓPTIMA.	104
GRÁFICO 3: PORCENTAJE DE COBERTURA RESULTADOS AG CON LA CONFIGURACIÓN ÓPTIMA.	104
GRÁFICO 4: FITNESS RESULTADOS AG CON LA CONFIGURACIÓN ÓPTIMA.	105
GRÁFICO 5: RESULTADOS AG CON LA CONFIGURACIÓN ÓPTIMA.	106
GRÁFICO 6: EVOLUCIÓN FITNESS/COBERTURA/Nº ANTENAS PARA LA MEJOR SOLUCIÓN DEL AG.....	107
GRÁFICO 7: Nº DE ANTENAS RESULTADOS RNDHORMIGAS MODIFICADO CON LA CONFIGURACIÓN ÓPTIMA Y COBERTURA COMO UMBRAL.....	115
GRÁFICO 8: PORCENTAJE DE COBERTURA RESULTADOS RNDHORMIGAS MODIFICADO CON LA CONFIGURACIÓN ÓPTIMA Y COBERTURA COMO UMBRAL.	115
GRÁFICO 9: FITNESS RESULTADOS RNDHORMIGAS MODIFICADO CON CONFIGURACIÓN ÓPTIMA Y COBERTURA COMO UMBRA.	116
GRÁFICO 10: RESULTADOS RNDHORMIGAS MODIFICADO COBERTURA CON LA CONFIGURACIÓN ÓPTIMA.	117
GRÁFICO 11: EVOLUCIÓN MEJOR SOLUCIÓN RNDHORMIGAS MODIFICADO COBERTURA MOSTRANDO LOS RESULTADOS DE LA MEJOR SOLUCIÓN DE CADA POBLACIÓN (EJE X: POBLACIÓN).	119
GRÁFICO 12: Nº DE ANTENAS RESULTADOS RNDHORMIGAS MODIFICADO.....	124
GRÁFICO 13: PORCENTAJE DE COBERTURA RESULTADOS RNDHORMIGAS.....	125
GRÁFICO 14: FITNESS RESULTADOS RNDHORMIGAS MODIFICADO CON CONFIGURACIÓN ÓPTIMA Y ANTENAS COMO UMBRA.	125
GRÁFICO 15: RESULTADOS RNDHORMIGAS MODIFICADO ANTENAS CON LA CONFIGURACIÓN ÓPTIMA.	126
GRÁFICO 16: EVOLUCIÓN MEJOR SOLUCIÓN RNDHORMIGAS MODIFICADO ANTENAS MOSTRANDO LOS RESULTADOS DE LA MEJOR SOLUCIÓN DE CADA POBLACIÓN (EJE X: POBLACIÓN).	128
GRÁFICO 17: EVOLUCIÓN DE LA MEJOR SOLUCIÓN DE RNDHORMIGAS ORIGINAL CON ANTENAS COMO UMBRAL, MOSTRANDO LOS RESULTADOS DE LA MEJOR SOLUCIÓN DE CADA POBLACIÓN (EJE X: POBLACIÓN).	135
GRÁFICO 18: EVOLUCIÓN DE LA MEJOR SOLUCIÓN DE RNDHORMIGAS ORIGINAL CON PORCENTAJE DE COBERTURA COMO UMBRAL, MOSTRANDO LOS RESULTADOS DE LA MEJOR SOLUCIÓN DE CADA POBLACIÓN (EJE X: POBLACIÓN).	141
GRÁFICO 19: Nº DE ANTENAS RESULTADOS ALGORITMO DE COLONIAS DE HORMIGAS CON CONFIGURACIÓN ÓPTIMA.	148
GRÁFICO 20: PORCENTAJE DE COBERTURA RESULTADOS ALGORITMO DE COLONIAS DE HORMIGAS CON CONFIGURACIÓN ÓPTIMA.	148
GRÁFICO 21: FITNESS RESULTADOS ALGORITMO DE COLONIAS DE HORMIGAS CON CONFIGURACIÓN ÓPTIMA.	149
GRÁFICO 22: GRÁFICO DE DISPERSIÓN DE LAS SOLUCIONES CON LA CONFIGURACIÓN ÓPTIMA PARA EL ALGORITMO DE COLONIAS DE HORMIGAS CON CLUSTERING.	150
GRÁFICO 23: REPRESENTACIÓN GRÁFICA DE LA EVOLUCIÓN DE LA MEJOR SOLUCIÓN DEL ALGORITMO DE COLONIAS DE HORMIGAS CON CLUSTERING.	152

GRÁFICO 24: GRÁFICO COMPARATIVO DE LA EVOLUCIÓN EN EL VALOR DEL FITNESS PARA LA MEJOR SOLUCIÓN DE CADA ALGORITMO BIOINSPIRADO ESTUDIADO.	161
GRÁFICO 25: GRÁFICO DE COLUMNAS COMPARATIVO SOBRE LOS MEJORES RESULTADOS PARA LOS ALGORITMOS BIOINSPIRADOS ESTUDIADOS EN FUNCIÓN DEL FITNESS, PORCENTAJE DE COBERTURA Y Nº DE ANTENAS.	162
GRÁFICO 26: GRÁFICO DE COLUMNAS COMPARATIVO SOBRE LOS VALORES MEDIOS PARA LOS ALGORITMOS CON LA CONFIGURACIÓN ÓPTIMA DE CADA UNO DE ELLOS.	163

Capítulo 1

Estado del Arte

1.1. Introducción.

En la sociedad actual, que podría clasificarse como una sociedad informacional, las telecomunicaciones se han convertido en uno de los símbolos de mayor relevancia. El rápido crecimiento que se ha producido en los servicios destinados al usuario, por el uso de redes de telefonía móvil, redes inalámbricas y redes de sensores, ha convertido la Telecomunicación en un campo con numerosas líneas de investigación abiertas. A medida que se solicitaban más servicios de telecomunicaciones, el número y complejidad de las redes ha ido creciendo, hasta el punto de hacer de la gestión de antenas, un problema de gran complejidad. Esto provoca que cada vez resulte más necesario contar con técnicas rápidas y fiables que permitan dar soporte al diseño de estas redes.

Ante estas circunstancias, se puede decir que el diseño de las redes de comunicación se enfrenta a tres grandes desafíos:

- 1) El imparable crecimiento del número de usuarios, que obliga a los operadores a rediseñar y adaptar sus redes de comunicación.
- 2) El surgimiento de las nuevas tecnologías de tercera generación.
- 3) Y por último, la necesidad de diseñar y establecer todas estas nuevas redes en el menor tiempo posible.

Dentro de este gran campo que es la Telecomunicación, los tipos de problemas con los que nos podemos encontrar son muchos y muy variados. Entre los que pueden ser caracterizados como problemas de optimización, podemos mencionar dos: la asignación de frecuencias en enlaces de radio y el diseño de la red de telecomunicaciones propiamente dicha. Por un lado, el problema de la asignación de frecuencias está relacionado con establecer la amplitud y tipología de frecuencia para los terminales o estaciones base. Por otro, el problema del diseño de la red consiste en determinar, de

entre una serie de posiciones potenciales, donde se situarán las antenas necesarias, teniendo en cuenta una serie de objetivos y restricciones.

Otro problema que despierta gran interés, es el diseño de una red de comunicación mediante la asignación de terminales. El objetivo de este problema no es otro que conseguir minimizar el coste de conectar un conjunto de terminales a una serie de concentradores para crear una red de comunicación, en donde cada terminal tendrá asociado un tráfico determinado y debe estar conectado a uno y sólo un concentrador.

Dentro del problema de diseño de redes de comunicación, la determinación de las posibles localizaciones de las antenas, resulta una tarea fundamental, ya que el lugar que ocupa una antena, determina la zona de cobertura de la misma y por tanto decidir las localizaciones del conjunto de antenas, establecerá la zona de cobertura, el grado de la misma e incluso el número de antenas necesarias.

A lo largo de toda la historia de la Informática, este tipo de estudios de optimización han sido de gran relevancia, ya que cualquier problema de búsqueda, optimización y aprendizaje permiten realizar múltiples análisis sobre el diseño de distintos algoritmos.

Este trabajo, se centrará en el estudio de los resultados obtenidos con distintos algoritmos bioinspirados para el problema concreto del diseño de redes de comunicación para un escenario concreto. Para poder comprender mejor todo lo que se desarrollará y el problema en concreto que se pretende abordar, se realizará en primer lugar una descripción del problema, así como los distintos estudios realizados para el mismo con anterioridad.

1.2. Descripción del Problema RND.

Tras la introducción anterior, en este apartado se procede a realizar una descripción más completa del problema RND (Radio Network Design), con el objetivo de facilitar la comprensión del resto del documento. Así, se hablará de en qué consiste el problema, los parámetros que lo definen, sus objetivos y restricciones.

El problema RND podría describirse como un problema de cobertura de señales de radio, ya que lo que pretende es proporcionar cobertura a un área empleando para ello una serie de transmisores o antenas. De este modo, si consideramos que estamos ante un escenario urbano al que se desea ofrecer cobertura de señal de radio, el área cubierta se convierte en un factor esencial. Para ello, se debe tener en cuenta, que a pesar de que se quiere proporcionar cobertura a la mayor área posible, los recursos de los que normalmente se disponen son limitados, por lo que surge la necesidad de limitar el número de transmisores. Resumiendo, se puede decir, que el problema RND consiste en diseñar una red de señal de radio que consiga ofrecer el mayor porcentaje de cobertura, pero empleando el menor número de antenas posibles; se pretende maximizar la cobertura, minimizando el número de transmisores empleados.

A la hora de enfrentarnos a este tipo de problema, es necesario que previamente se haya realizado un estudio que determine una lista de localizaciones aptas para la futura colocación de estas antenas (*“problema APP”*): lugares con buena visibilidad, sin obstáculos cercanos como pueden ser tejados de edificios bastante altos, y alejados de zonas no permitidas, hospitales o los colegios. Con esto, se conseguirá un centenar o incluso miles de puntos, repartidos por el área que se desea cubrir de manera más o menos uniforme, para posteriormente escoger de entre ellos, dónde colocar las antenas. Esta tarea previa, puede ser decisiva para la resolución del problema, ya que dependiendo de lo buena que sea esta lista de posibles localizaciones, dependerá el resultado final del problema RND, ya que se debe conseguir que estos emplazamientos estén distribuidos de manera uniforme por toda el área, y que alcancen a dar cobertura a toda la zona.

Tras esto, podemos concretar algo más la definición del problema RND, diciendo que se encarga de seleccionar un subconjunto de localizaciones de entre el conjunto de emplazamientos posibles para colocar una antena, intentando maximizar la cantidad de

área cubierta por las mismas, pero minimizando al mismo tiempo el número empleado de dichas antenas.

Para la resolución de este problema, se tienen en cuenta una serie de parámetros o entidades: a) el área de trabajo; b) las antenas o estaciones base (Base Station (BS)).

a) Área de Trabajo.

Al hablar de área de trabajo, se hace referencia a la representación de la zona a la que se pretende dar cobertura mediante la colocación de una serie de antenas.

Esta área de trabajo, puede representarse de distintas formas, aunque la forma más habitual, que será la que aquí se desarrolle, es la presentada por Calégari en [2], donde se empleó la digitalización del terreno como una rejilla rectangular, dividida en una serie de sectores o localizaciones, cada uno de los cuales se encuentra representado por unas coordenadas (x,y).




Ilustración 1: Ejemplo Representativo Discretización del Área de Trabajo

Ante este tipo de representación del terreno, se decide que el conjunto de posibles localizaciones donde colocar una antena, mencionado anteriormente, se represente como una lista de coordenadas (x,y), consiguiendo de este modo, una lista de celdas del área de trabajo donde se pueden colocar las antenas. Para que todo esto tenga sentido, se considera que la discretización es lo suficientemente precisa como para que cualquier posición de la antena dentro del sector resulte en una misma y única celda de cobertura.

b) Antenas o BS's.

En lo referente a las antenas o estaciones bases, destacar que se trata simplemente de la representación en el área de trabajo de la existencia en una celda de una antena.

Al hablar de antenas dentro de la idea del problema RND, se debe señalar que éstas poseen unas series de características que las definen:

1. **Topología:** Esta característica hace referencia al tipo de cobertura que ofrece la antena; es decir, si ofrece un tipo de cobertura cuadrada, circular, etc.




Ilustración 2: a) Antena Cuadrada y b) Antena Circular u Omnidireccional.




Ilustración 3: Representación Rejilla con a) Antenas Cuadradas y b) Circulares.

2. **Radio de Cobertura:** Se refiere al radio de alcance de cobertura para cada antena.

Teniendo en cuenta esta información, si dos o más antenas se encuentran situadas lo suficientemente cerca la una de la otra; es decir, la diferencia espacial entre ellas es menor que su radio de cobertura, se producirá solapamiento en aquellas localizaciones a las que ambas dan cobertura, y por tanto, existirán diferentes grados de cobertura. Por esta razón, es necesario que cada una de las celdas del área de trabajo del problema almacene una serie de información: el grado de cobertura, si es o no un posible emplazamiento para una antena y si existe o no una antena en dicha localización.




Ilustración 4: Ejemplo de tres antenas en la Rejilla y su área de cobertura, así como a las celdas que proporcionan cobertura.

Siguiendo este camino, se establece la *función de adaptación o función fitness* para el problema, que servirá para evaluar como de buenas son las soluciones que se irán obteniendo. Por tanto, y teniendo en cuenta lo comentado acerca del problema RND hasta el momento, se define la función fitness como una relación entre el porcentaje de área cubierta y el número de antenas empleadas:

$$F = (\% \text{ cobertura})^2 / \text{número de antenas}$$

Para concluir, se puede decir que un diseño de red consiste simplemente en un subconjunto de coordenadas. Así, cualquier subconjunto válido, constituye una solución del problema, codificándose cada una de ellas como cadenas binarias en donde cada bit corresponde de forma unívoca con una localización de la lista, y en donde un bit a “1” representa la presencia de antena en esas coordenadas y un bit a “0”, indica justo lo contrario, la ausencia de antena en dicha localización. Se trata de un típico problema de optimización combinatoria NP-Difícil (“NP-Hard”).

1.3. Descripción del Dominio OPLINK.

El problema que se pretende resolver en este trabajo es el denominado RND, sin embargo, el escenario concreto sobre el que se va a trabajar es un caso particular de este problema global, que proviene de un proyecto del Ministerio de Tecnología y Cultura que recibe el nombre de OPLINK.

La elección de este dominio concreto para centrar el estudio, se debe principalmente a que se trata de un problema ya estandarizado del que se poseen datos y las características propias del problema como es el terreno, la lista de posible localizaciones de antenas, etc., sin olvidar que existen estudios previos sobre el mismo para poder comparar los resultados.

Este problema RND dentro del marco del proyecto OPLINK, se puede considerar una simplificación del problema general, ya que establece una serie de restricciones y suposiciones:

- a. Se posee información acerca del conjunto de posibles emplazamientos para las antenas que establezcan el diseño de la red.
- b. El área de trabajo se representará como una rejilla de $M \times N$ dimensiones, que en este caso concreto contará con 300 filas x 450 columnas, para representar la ciudad de Málaga en España. Destacar que el tamaño real de la rejilla será de 4.25 x 6.4 kilómetros, lo que hace que cada celda de la rejilla represente aproximadamente 15 x 15 metros.



Ilustración 5: Mapa de Málaga, España.

- c. Las antenas de las que se dispone para el diseño de la red, tendrán una topología circular con un radio de 450 metros cada una de ellas, lo que se traduce en un radio de 30 celdas en la representación en la rejilla rectangular que representa el área de trabajo.

En este escenario, el objetivo final continúa siendo el mismo, buscando siempre maximizar la cobertura, minimizando el número de antenas empleadas, por lo que la función de fitness a emplear, continúa siendo:

$$F = (\% \text{ cobertura})^2 / \text{número de antenas}$$

Ante este dominio, existen otras vías de estudio para solucionar el problema RND, al margen de la propuesta en este proyecto. Al proyecto de investigación del problema RND sobre este dominio concreto se encuentran asociadas 4 universidades, que han aplicado distintas técnicas a la hora de abordar el problema:

1. **Universidad de Málaga (UMA):** Esta universidad ha aplicado técnicas metaheurísticas como Simmulated Annealing y CHC para solucionar el problema RND.
2. **Universidad de La Laguna (ULL):** Ha desarrollado el problema aplicando la técnica VNS (*Variable Neighborhood SEACC*).
3. **Universidad de Extremadura (UEX):** Aplicando técnicas como Differential Evolution, PBIL, Test Fitness y GRASP para alcanzar la solución al problema.
4. **Universidad Carlos III de Madrid (UC3M):** Centrada en los algoritmos desarrollados en el presente documento, así como Algoritmos meméticos y Chromosome Appearance Probability Matrix, los cuales han sido desarrollados en otros proyectos.

1.4. Distintos estudios realizados para la resolución del problema RND.

Desde que surgió el problema de Diseño de Redes de Señal de Radio (RND), se han desarrollado numerosos estudios sobre el tema. En lo que se refiere a técnicas informáticas, son varias las contribuciones relevantes que se han hecho a lo largo del tiempo

En este apartado, se pretende recoger un resumen de los estudios más relevantes realizados hasta la fecha, presentándolos en orden cronológico para poder completar una idea general de todo el avance.

1.4.1. Cellular Radio Network Planning (A. Gamst et al., 1986).

En 1986, Gamst presenta en [25] un enfoque para abordar el problema RND al que se denominó “Analytical Approach to Cellular Network Planning”, o lo que es lo mismo, “Enfoque Analítico Convencional”.

En base a este enfoque, se desarrollaron una serie de herramientas que aún se utilizan para la planificación de redes de telecomunicación, como son PEGASOS de T-Mobil en 1996 o PLANET de MSI Plc. de 1996.

Este estudio desarrollado para dar solución al problema de diseño de redes, se centraba en determinar los parámetros de los transmisores o antenas: localización, topología y poder de alcance del transmisor.

Tal y como se diseñó, se puede decir que consta de 4 fases distintas que se repetirán varias veces de forma iterativa: 1) Definición de la Red de Radio; 2) Análisis de Propagación; 3) Asignación de Frecuencias; y 4) Análisis de la Red de Radio.



Ilustración 6: Esquema Enfoque Analítico.

1) Definición Red de Radio: Busca obtener aquellos posibles emplazamientos donde posteriormente se colocará un transmisor. Esta fase la realizará un experto en la materia, que será el encargado de determinar las posibles localizaciones. Lo más habitual en estos casos, es realizarlo teniendo en cuenta el concepto de que las antenas se distribuirán en celdas de una rejilla hexagonal.

2) Análisis de Propagación: Evaluará el radio de cobertura mediante el uso de métodos de predicción de campo de fuerza.

3) Asignación de Frecuencias: Su objetivo es crear una “matriz de tráfico”, que contendrá una distribución del tráfico de telecomunicación esperado para el área de trabajo. Con esta información, se podrá calcular las frecuencias de cada celda del terreno así como el número de canales de tráfico que serán necesarios.

4) Análisis Red de Radio: Fase responsable de calcular los valores de calidad del servicio del área con respecto a situaciones de bloqueo y probabilidades de caída de la red.

Si los valores que se obtienen, cumplen con los requerimientos establecidos para el servicio, se dará por concluido el proceso, en caso contrario, será necesario regresar a la primera fase, y repetir todo el proceso.

Este tipo de enfoque, presenta algunas desventajas, entre las que destaca las restricciones a los objetivos del diseño RF. Las cuestiones acerca de la red y su capacidad se encuentran más o menos descuidadas por este enfoque. Además, los pasos de diseño se tratan de forma independiente lo que hace que los objetivos globales sean más difíciles de obtener.

1.4.2. *Field strength prediction by ray-tracing for adaptive base station positioning in mobile communication network*
(Th. Fritsch et al., 1993 y 1995)

El Algoritmo Adaptativo de Posicionamiento de Estaciones Base (Adaptive Base Station Positioning Algorithm (ABPA)), fue presentado por primera vez por Fritsch y Hanshans en 1993 y Fritsch en 1995 [3].

Este algoritmo, hace uso de una versión del concepto de Nodo de Demanda². Este fue uno de los primeros métodos en considerar el tráfico de red esperado, de forma paralela a los objetivos RF, como una limitación directa para la ubicación de las antenas.

ABPA se basa en la idea de competición de estaciones base, el cual intenta cubrir tantos nodos de demanda como sea posible. Para ello, el algoritmo determina dos parámetros de los transmisores, su localización y su poder de transmisión. Para localizar las estaciones base, el algoritmo produce cambios en los transmisores en un escenario virtual. Así, el movimiento de las estaciones base se encuentra conducido por su atracción a aquellas zonas en donde no se han cubierto los nodos de demanda y por su repulsión a aquellas zonas en donde estos ya han sido cubiertos por múltiples estaciones base.

El principal problema que podría presentar este algoritmo, sería el de caer con demasiada facilidad en óptimos locales, lo que quedaba resuelto al introducir en el algoritmo una cierta probabilidad con la que buscar una configuración peor que de solución al problema.

1.4.3. ICEPT – An Integrated Cellular Network Planning Tool. (P. Tran-Gia et al., 1997).

El **Enfoque Integrado** consigue superar las deficiencias presentadas por el enfoque convencional, explicado con anterioridad, organizando las limitaciones del diseño de la red y sus objetivos en cuatro módulos principales, tal y como demostró Tutschku en 1996 en [5]. Estos módulos, se corresponden con la identificación de cuatro grandes aspectos referentes al diseño de redes de comunicación, teniendo en cuenta sus puntos clave de manera global.

Las interacciones y dependencias entre los diferentes aspectos del diseño pueden ser incluidas en este enfoque gracias a la explotación modulada. Esta división permite que las dependencias del modelo sean abstraídas de una forma totalmente comprensible y adecuada, mediante su representación en “Nodos de Demanda”¹.

Se introduce así una discretización de la demanda de tráfico tanto en concepto de demanda como de espacio, consiguiendo constituir un modelo estático de población para la descripción del comportamiento del suscriptor móvil. Por lo tanto, los nodos de demanda se encontrarán de forma más densa en aquellas áreas en las que exista un alto nivel de demanda de tráfico, y estarán más esparcidos en aquellas áreas en las que se demande menos tráfico, tal y como se puede observar en la Ilustración 7.

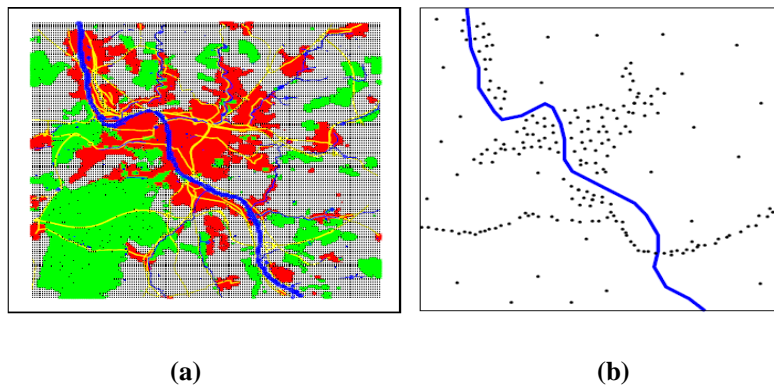


Ilustración 7: (a) Datos Geográficos y Demográficos y (b) Distribución de Nodos de Demanda.

¹ Definición Nodo de Demanda: Un nodo de demanda representa el centro de un área conteniendo una cantidad de demanda desde un punto de vista de tráfico de comunicación, representando un número fijo de llamadas solicitadas por unidad de tiempo.

Explotando la idea de los nodos de demanda, y antes de comenzar a ejecutar los distintos módulos de los que se compone el enfoque integrado, se realiza un proceso (Mobile User Characterization) que consta de tres fases:

1. **Preprocesamiento** de la información geográfica y demográfica.
2. **Definición del modelo espacial del tráfico** para la demanda de tráfico de telecomunicación.
3. Generación de la **discretización de la distribución de los nodos de demanda**.




Ilustración 8: Ilustración del Proceso de generación de los nodos demanda.

Retomando la idea de la organización modular de este enfoque, cabe destacar que los cuatro módulos de los que se compone son: **Transmisión de Radio** (Radio Transmission), **Suscriptor Móvil** (Mobile Subscriber), **Asignación de Recursos** (Resource Allocation) y **Arquitectura del Sistema** (System Architecture), que contribuyen a la integración de un componente de mayor nivel, **Diseño Automático de la Red** (Automatic Network Design), encargado de gestionar los diferentes objetivos que se pretenden alcanzar.

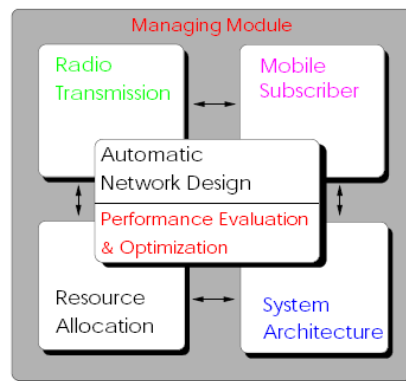


Ilustración 9: Organización Enfoque Integrado.

Desde el momento en el que este enfoque integrado considera que los aspectos de diseño no pueden ser tratados de forma totalmente independiente, se hace posible el obtener soluciones que optimicen más de un objetivo, consiguiendo resolver los conflictos de los objetivos del diseño y encontrando mejores soluciones que el enfoque convencional.

1.4.4. Genetic Approach to Radio Network Optimization for Mobile Systems. (P. Calegari et al., 1997).

En 1997, Calegari y otros presentan en [12] una propuesta para emplear un algoritmo genético canónico para solucionar el problema RND.

El algoritmo que se propone en este caso, se trata de un algoritmo genético canónico, en el cual se emplea para la selección, el método de la ruleta; un tipo de cruce simple con un único punto y una mutación de un bit seleccionado al azar con una probabilidad del 90%.

En este estudio, la función de fitness empleada es la misma que se mencionó con anterioridad a la hora de describir el problema RND.

El escenario en el que se probó este algoritmo se caracterizaba por tener un área de trabajo representada en una rejilla de 300 filas x 300 columnas con una lista de 150 localizaciones potenciales para las antenas.

Los resultados que se obtuvieron con este método fueron bastante buenos, sin embargo, según la opinión de los expertos existían dos problemas principales: que el número de antenas que se empleaba era excesivo y, por otra parte, que se tardaba demasiado tiempo en obtener una solución.

1.4.5. A Multiobjective Genetic Algorithm for Radio Network Optimization. (H. Meunier et al., 2000).

Tras probar a resolver el problema RND con algoritmos genéticos simples, en el año 2000 H. Meunier y P. Reininger presentaron en [7] la posibilidad de solucionar el problema con algoritmos genéticos multiobjetivo. La solución propuesta buscaba alcanzar dos objetivos diferentes: la convergencia hacia el frente de Pareto, y conseguir diversidad de soluciones.

Los operadores genéticos empleados para este algoritmo fueron un tipo de selección basada en ruleta, un tipo de cruce con el que seleccionaban dos padres pero generaban un único hijo, y una mutación que se aplicaba únicamente sobre el mejor individuo de toda la población. Tras esto, se aplicaba elitismo, introduciendo en la nueva población la mejor solución de la población anterior.

Este algoritmo fue evaluado en un escenario real donde el terreno era de aproximadamente 39 Km. x 168,8 Km., con 250 posibles localizaciones para las antenas. Tras su ejecución, se obtuvieron resultados que conseguían dar servicio al 75% del tráfico empleando únicamente 54 antenas. A pesar de esto, tal como ocurría con otros estudios previos, el principal problema de este algoritmo fue que tardaba demasiado tiempo en generar una solución.

1.4.6. Applying Data Mining Methods for Cellular Radio Network Planning. (Piotr Gawrysiak y Micha Okoniewski, 2000).

Gawrysiak y Okoniewski presentan en [23] en el año 2000 como se pueden aplicar técnicas de minería de datos para ayudar a la resolución del problema de planificación de redes de telecomunicación.

Las técnicas de minería de datos no sirven, en sí mismas, para resolver el problema RND, ya que no permiten configurar y establecer las localizaciones de las antenas, tal y como hacen otro tipo de técnicas como los algoritmos genéticos. Sin embargo, y según se comenta en el artículo, resultan muy útiles cuando se combinan con alguna de las técnicas mencionadas, principalmente para la realización de tareas concretas dentro de

la planificación de las redes de telecomunicación, como puede ser predecir el tráfico de una determinada zona, etc.

Entre las técnicas que proponen aplicar en este contexto destacan los árboles de decisión, el clustering de datos mediante el algoritmo K-Medias, Redes Neuronales, Regresión y Reglas de Asociación.

1.4.7. Radio network design using coarsegrained parallel genetic algorithms with different neighbor topology. (G. Tongcheng y M. Chundi, 2002).

Los algoritmos genéticos simples pueden paralelizarse fácilmente empleando un modelo maestro/esclavo, en el que el maestro ejecuta el algoritmo secuencial tradicional, pero envía a los procesadores esclavos los individuos para su evaluación en paralelo. De este modo, se puede ahorrar tiempo cuando la función de evaluación es costosa o bien cuando el número de equipos es moderado. Al estructurar la población se puede conducir a uno de los dos modelos clásicos que se utilizan en las implementaciones paralelas: modelo distribuido o modelo celular.

Un Algoritmo genético distribuido suele tener una población mucho mayor que un individuo, y además suele mostrar una evolución desacoplada, utilizando pocos sub-algoritmos.

En el Caso de los Algoritmos Genéticos Paralelos, existen distintos sub-algoritmos ejecutando de forma paralela, un algoritmo genético de cualquier tipo sobre sub-poblaciones distintas, pudiendo ser estos algoritmos paralelos del mismo tipo o no. Cada sub-algoritmo ejecuta la política de intercambio enviándose información con un conjunto de algoritmos vecinos.

Con este tipo de técnica, en el año 2002, la universidad de Tsinghua presenta en [27], la posibilidad de resolver el problema RND de una forma más efectiva. En este caso, se utilizó un escenario con un área de 287x287 celdas en su representación en forma de rejilla, en donde las antenas se caracterizaban por proporcionar una cobertura cuadrada de radio 41. En este caso, la parte paralela del algoritmo se desarrolló mediante un diseño basado en 16 islas distribuidas en una serie de procesadores, donde cada una de ellas, posee una población de 10 individuos. Con esta técnica, consiguieron

alcanzar el mayor valor de fitness posible con una reducción notable del tiempo de ejecución utilizando 8 procesadores.

1.4.8. Evolutionary Algorithms for Optimal Placement of Antennae in Radio Network Design. (E. Alba, 2004).

En el año 2004, Enrique Alba de la universidad de Málaga propone en [9] el uso de algoritmos evolutivos para dar solución al problema RND de diseño de redes de telecomunicación. El algoritmo evolutivo que propone en este caso, no es más que un algoritmo genético de estado estable así como su versión distribuida.

El escenario empleado para realizar las pruebas, es el caracterizado por un terreno representado en una rejilla de 287x287, donde existe una lista de 149 emplazamientos potenciales de antenas, las cuales se caracterizan por tener un tipo de cobertura cuadrada de radio 41.

Así mismo, presenta dos tipos de funciones fitness con el objetivo de encontrar la solución optima.

Los resultados que obtiene, funcionan apropiadamente sin necesidad de ayuda adicional. En cuanto al algoritmo genético de estado estable, proporciona un muy buen trabajo de búsqueda, sin embargo, el problema es que es demasiado lento. En la versión distribuida del algoritmo, que funciona en una red de estaciones de trabajo, se obtiene una ejecución mucho más rápida, reduciendo notablemente el tiempo de ejecución del algoritmo.

1.4.9. A Differential Evolution Based Algorithm to Optimize the Radio Network Design Problem. (S.P. Mendes et al., 2006).

La Universidad de Extremadura, de forma conjunta con la Universidad de Leiria, presenta en el año 2006 en [15], un estudio acerca de la resolución del problema RND empleando evolución diferencial.

La evolución diferencial es un algoritmo creado por Ken Price y Rainer Storn, que desde 1994 ha sido utilizado para resolver numerosos problemas de optimización con resultados muy satisfactorios. Se trata de un algoritmo iterativo, en donde las sucesivas

generaciones intentan obtener una solución óptima, que se detendrá cuando se encuentre una solución con el mejor valor posible de fitness o bien cuando se hayan sucedido un número máximo de generaciones.

El desarrollo de este algoritmo sigue los pasos convencionales de la computación evolutiva, empleando operadores de selección y cruce. En el caso del operador de cruce, se trabaja con cuatro individuos de la población, entre los que se encuentra el individuo objetivo, realizando el cruce entre dos de ellos, para posteriormente realizar un nuevo cruce entre el nuevo individuo generado y el tercer individuo seleccionado, repitiendo este mismo proceso entre el nuevo individuo generado de este cruce con el cuarto y el último individuo seleccionado. Si el individuo generado de estos cruces sucesivos es mejor que el individuo objetivo se sustituye por este.

Para obtener los resultados de este algoritmo en la resolución del problema RND, se eligió un escenario con un terreno en el que la rejilla tenía 287x287 localizaciones, una lista de 349 posibles emplazamientos y antenas con cobertura circular.

Los resultados dejaron patente que desde un punto de vista de modelado, el algoritmo es capaz de enfrentarse al problema, tendiendo cuidado en su construcción y en la elección de la función de cruce. Además, estos resultados probaron que es posible obtener localizaciones satisfactorias para conseguir cubrir la máxima área posible con un número determinado de antenas.

Sin embargo, este algoritmo necesita de muchas mejoras en el código, como un método de cruce nuevo y más eficiente, probar con más tipos de topología en la cobertura de la antena, etc. Además, este algoritmo puede llegar a ser parcial, ya sea hacia el índice de cobertura o en términos de los transmisores, por lo que se cree que funcionaría mejor con algún algoritmo multiobjetivo.

1.4.10. Using Omnidirectional BTS and Different Evolutionary Approaches to Solve the RND Problem. (S.P. Mendes et al. 2007).

En este trabajo, los autores comparan el rendimiento de cuatro algoritmos sobre una instancia del problema RND. Las alternativas evaluadas son la evolución diferencial, population-based incremental learning, simulated annealing y CHC.

El escenario empleado para probar los algoritmos se caracteriza por centrarse en un área representada por una rejilla de 287x287 con una lista de 349 posibles emplazamientos de antenas y en donde cada una tiene una cobertura circular de radio 22 sectores o celdas.

Los resultados muestran cómo CHC y SA proporcionan los mejores resultados en términos de cobertura (un 90% en ambos casos). Los autores sostienen que entre estas alternativas, CHC resulta más interesante porque obtiene los mismos resultados pero exigiendo un menor esfuerzo computacional (1,400,000 evaluaciones de CHC frente a 4.152,235 de SA). La peor cobertura la ofrece la evolución diferencial (72,30%), pero a cambio, resulta ser el algoritmo menos exigente en términos computacionales (4,914 evaluaciones). A este respecto, los autores sugieren que la baja cobertura en comparación con el resto, podría explicarse por la naturaleza continua de su funcionamiento, que podría provocar que el algoritmo tuviese más tendencia a quedarse atascado durante la búsqueda en este dominio. Por último PBIL consigue coberturas del 85% con 333.045 evaluaciones. Esto deja al algoritmo en una posición intermedia en ambos ejes de comparación.

1.4.11. Optimal Antenna Placement Using a New Multi-Objective CHC Algorithm. (A. J. Nebro et al., 2007).

Estos autores prueban a solucionar el problema RND en el mismo escenario propuesto por S.P. Mendes y otros colaboradores en [17], mediante una variante multiobjetivo de CHC

Parte de estos investigadores ya utilizaron con éxito la versión básica de CHC sobre RND. En [13], Enrique Alba y sus colaboradores llegaron a la conclusión de que el algoritmo CHC era una de las mejores técnicas para dar solución a este problema, ya que se conseguían buenos resultados con un coste computacional y temporal suficientemente bajo.

El funcionamiento de este algoritmo CHC multiobjetivo, es el mismo que en el escenario clásico, salvo que se sustituye el funcionamiento del criterio elitista. En la versión multiobjetivo de este algoritmo, los individuos ya no se ordenan en base a un valor fitness, sino que lo harán mediante un método de ranking y crowding.

Los resultados que se obtuvieron para la resolución del problema RND con este algoritmo CHC multiobjetivo fueron muy favorables, ya que mejoraron los resultados existentes hasta el momento, y el beneficio que obtuvieron fue doble, ya que consiguieron alcanzar la solución óptima con un coste computacional bastante bajo, sino que además este algoritmo ofrece todo un conjunto final de soluciones no dominadas entre las que poder escoger al final sin tener en cuenta prejuicios de optimalidad.

1.4.12. Desktop Grid Computing with BOINC and its use for Solving the RND Telecommunication Problem. (Juan A. Gómez et al. 2007).

En el escenario del e-Science Grid Computation, se presentó la propuesta de utilizar PBIL o Population-Based Incremental Learning para el problema RND en [24].

PBIL es un método que combina un algoritmo genético con aprendizaje competitivo para funciones de optimización. En el algoritmo PBIL, en lugar de emplear los operadores, infiere una probabilidad de distribución desde la población actual y los ejemplos de la nueva, desde la distribución inferida.

El algoritmo, utiliza el concepto de población de cromosomas con distribuciones de probabilidad aplicadas a los genes. Estas probabilidades se expresan en lo que se llama vector de probabilidad, que se usa para generar la siguiente población, usando para su actualización una regla que considera la mejor solución encontrada hasta ese momento.

Para la ejecución de los experimentos, se utilizó un entorno de pruebas que emplea una rejilla representativa del terreno de 257x257 celdas con 349 posibles emplazamientos de antenas, en donde cada una de estas posee una cobertura cuadrada de radio 20. Ante este escenario, se consiguen alcanzar buenos resultados con la ejecución de este algoritmo, llegando al 100% de cobertura con 49 antenas.

Igualmente, este algoritmo fue empleado para realizar otro estudio para el diseño de redes con antenas omnidireccionales en [19]. En este caso, el escenario en el que se realizan las pruebas posee una rejilla de 287x287 celdas, con una lista de 349 posibles localizaciones para las antenas, y como ya se ha mencionado con anterioridad, se trabaja con antenas omnidireccionales de cobertura circular con un radio de 22 celdas.

En este trabajo, el objetivo se basaba en establecer correctamente una buena configuración para el algoritmo PBIL, centrándose principalmente en el tamaño de la población, probabilidad de mutación, intensidad de la mutación que afecta al vector de probabilidad, el índice de aprendizaje y si se emplea el método de elitismo o no. Los resultados que se obtuvieron ante este escenario, fue de un 85% de cobertura con tan solo 62 antenas, lo que se consideró un resultado bastante aceptable.

Capítulo 2

Objetivos

2.1 Introducción

Con el desarrollo del presente proyecto, se tiene como objetivo resolver el problema RND (Radio Network Design), que trata de dar solución al diseño de redes de comunicación, y que se encuentra enmarcado dentro del terreno de las telecomunicaciones. Tal y como ya se explicó en el capítulo anterior del presente documento, este problema trata de conseguir dar cobertura a la mayor superficie posible de un terreno determinado, colocando estratégicamente el mínimo número posible de antenas para proporcionar dicha cobertura.

Por lo tanto, este problema trata de obtener unas soluciones que consigan maximizar la cobertura proporcionada, minimizando el número de antenas empleadas para ello. Con el desarrollo de este proyecto, se pretende probar nuevas técnicas o modificaciones de otras existentes, para dar solución a este problema en un escenario concreto, con el objetivo de obtener unos resultados competitivos en referencia a los obtenidos en estudios anteriores.

Este problema sobre el diseño de redes de comunicación, resulta muy interesante desde diversos puntos de vista. En primer lugar, el problema RND resulta muy atractivo desde un punto de vista de investigación. Los problemas de optimización han resultado poseer un gran atractivo para el campo de la investigación a lo largo de la historia, y este problema, se convierte en un candidato idóneo ya que permite estudiar una gran diversidad de técnicas de planificación y computación biológica, al tratarse de un problema “multiobjetivo”, en donde ambos objetivos, podrían considerarse contrapuestos.

Asimismo, resulta llamativo por su gran importancia económica. Hablamos de un problema de gran impacto económico para las empresas proveedoras de servicios de comunicación, para las que se convierte en un problema de gran interés, ya que pretenden conseguir grandes ingresos consiguiendo proporcionar el mejor de los

servicios a sus clientes, para conseguir mantenerlos o atraerlos de otras compañías. Esto se traduce en ofrecer una cobertura total, o la mayor posible en su área de servicio, pero estableciendo un equilibrio entre este máximo de cobertura, y las antenas o repetidores empleados, ya que de nada sirve tener muchos clientes gracias a una gran cobertura, si para ello se necesita emplear un gran número de antenas, cada una de ellas de enorme coste y mantenimiento, que reduce los beneficios de la empresa.

2.2 Aproximaciones Iniciales

Inicialmente, y como introducción al problema, se realizó un acercamiento al mismo, mediante el desarrollo de un algoritmo genético en un escenario muy sencillo de ámbito académico. Con este estudio previo, simplemente se buscaba la familiarización con el problema, con el objetivo de comprender a la perfección todos los aspectos que involucraba, desarrollándose en un escenario suficientemente sencillo, para que posteriormente, su desarrollo en uno más complejo, como es el que se trata en el proyecto, no presentase ninguna dificultad.

Consiste en una aproximación relajada del problema, en donde el escenario con el que se trabaja, no se corresponde con ningún área real, pero que sin embargo, ha sido empleado en estudios previos, citados en el capítulo anterior del actual documento, para de este modo, poder comparar resultados y verificar el correcto desarrollo y desempeño del trabajo, ya que se conoce a priori la solución óptima del problema.

Se trata de un entorno de pruebas en donde se trabaja con un terreno representado mediante una rejilla de 287×287 celdas, obteniendo de este modo 82369 localizaciones, y en donde se dispone de una serie de antenas de cobertura cuadrada de 41×41 .

Para este problema, se trabajó con listas de 149, 199, 249, 299 y 349 emplazamientos potenciales de antenas, en donde se podía establecer que un número determinado de estas posiciones se distribuyese de forma uniforme sobre el terreno, mientras que el resto de posibles localizaciones se seleccionaban de forma pseudo-aleatoria.

Las pruebas que se realizaron, pretendían comprobar cómo se comporta el algoritmo, según se variaban una serie de parámetros propios del problema y no del algoritmo, puesto que estos últimos fueron estudiados con anterioridad, con el fin de

poder realizar estas pruebas, basándose únicamente en los parámetros del problema, y poder comparar los resultados obtenidos de ellas.

Para analizar el comportamiento del algoritmo, se tomó la decisión de estudiar los resultados obtenidos por el mismo, para los casos de establecer o no una distribución previa de posibles emplazamientos de antenas de manera uniforme. Con distribución previa de las localizaciones de las antenas de manera uniforme, se hace referencia al hecho de que como para este escenario no existe un conjunto preestablecido de posibles localizaciones, si no que se realiza al iniciar el algoritmo, se estudiarán los casos en los que se establezca que un número X de localizaciones no se establezcan de forma aleatoria si no que se distribuyan de manera uniforme por todo el territorio.

Por tanto, se establecieron unas pruebas que consistían en probar los resultados que se obtienen si no se establece ninguna de las localizaciones de antenas disponibles como uniformes en el territorio, probar los resultados que se obtienen si se establecen 25 antenas uniformemente de las disponibles, y por último probar los resultados que se obtienen si se establecen el total de 49 antenas de manera uniforme por el territorio, todo ello, como ya se ha comentado, en un territorio formado por 82369 localizaciones posibles (287x287). Estas tres opciones fueron probadas para cada una de las 5 posibilidades expuestas de número de lugares o situaciones donde se pueden colocar antenas: 149, 299, 249, 299 y 349.

En cuanto a los parámetros propios del algoritmo que se emplearon para la realización de estas pruebas, se establecieron los siguientes: un tamaño de población de 1000, ya que tras los estudios realizados se observó que era un tamaño de población suficientemente grande para obtener buenos resultados; se empleó un tipo de operador de selección basado en campeonato o torneo; se establece un periodo de estancamiento de 50 generaciones sin variación para efectuar la finalización del algoritmo o bien que se hayan ejecutado ya 1000 generaciones. Todas estas características y operadores se describirán con más detalle en el “Capítulo 4. Algoritmos Empleados”.

Destacar, que para este escenario, se realizaron pruebas con dos funciones de fitness diferentes. La primera de ellas es la original y la que se propone para la resolución del problema RND:

$$F = (\% \text{ cobertura})^2 / \text{número de antenas}$$

, y la segunda, fue ideada de manera propia para establecer un nuevo tipo de relación entre la cobertura y las antenas, fomentando la cobertura. Es decir, este nuevo fitness, se basa tanto en la cobertura como en el número de antenas, sin embargo, da prioridad a la solución con mayor cobertura, y si ésta fuese menor pero se encuentra dentro de un margen predeterminado, se premiará a aquella solución que utilice un menor número de antenas (ver “Capítulo4. Algoritmos Empleados”).

Ya que los algoritmos genéticos no siempre producen los mismos resultados, pues depende en gran grado de su inicialización aleatoria, se decidió establecer que para cada prueba, el algoritmo genético se ejecutaría un total de 80 veces para obtener una visión más real de los resultados obtenidos. Tras la recopilación de los resultados de todas las pruebas, las mejores soluciones obtenidas de cada una de ellas, empleando como función de fitness, la original propuesta por el problema, fueron los siguientes:

	Valor de Fitness	Porcentaje de Cobertura	Número de antenas	Generación en la que se encontró
Prueba1: 149 0 uniformes	143,46	82,98%	48	115
Prueba 2: 199 0 uniformes	148,90	84,54%	48	95
Prueba 3: 249 0 uniformes	151,50	83,48%	46	169
Prueba 4: 299 0 uniformes	150,17	90,05%	54	263
Prueba 5: 349 0 uniformes	142,13	88,41%	55	294
Prueba 6: 149 25 uniformes	175,88	90,92%	47	52
Prueba 7: 199 25 uniformes	172,54	89,08%	46	145
Prueba 8: 249 25 uniformes	171,56	92,61%	50	252
Prueba 9: 299 25 uniformes	169,14	91,96%	50	231
Prueba 10: 349 25 uniformes	157,88	91,47%	53	255
Prueba 11: 149 49 uniformes	204,08	100%	49	36
Prueba 12: 199 49 uniformes	204,08	100%	49	85
Prueba 13: 249 49 uniformes	202,27	99,55%	49	133
Prueba 14: 299 49 uniformes	195,63	97,90%	49	201
Prueba 15: 349 49 uniformes	178,49	98,17%	54	323

Tabla 1: Tabla de Resultados del Algoritmo Genético con Fitness Original en el Escenario Relajado.




Ilustración 10: Representación Gráfica Resultados Escenario Relajado con Fitness Original.

Tras observar los mejores resultados obtenidos en las distintas pruebas, se pueden llegar a plantear una serie de conclusiones generales a los resultados que se obtienen mediante la aplicación del algoritmo para lograr una solución al problema de distribución de antenas repetidoras planteado. Así se puede observar que:

1. Dentro de las pruebas realizadas, estableciendo para ellas, el mismo número de antenas distribuidas uniformemente, se puede observar como:
 - a. El porcentaje de cobertura, se mantiene, más o menos estable, entre ellas.
 - b. El número de antenas empleadas para la solución, aumenta a medida que se aumenta el número de posibles localizaciones donde situar las antenas. Esto se debe principalmente, a que ya que se dispone de un mayor número de posibles localizaciones, y por tanto, desde el punto del algoritmo, un mayor número de datos a tratar, resulta más complejo para éste, decidir en qué posiciones situar las antenas, si dispone de las mismas características que el resto de las pruebas realizadas para un menor número de posiciones.
 - c. El valor del fitness obtenido, tiende a mantenerse o disminuir, ya que si conseguimos el mismo porcentaje de cobertura pero el número de antenas empleadas aumenta, el valor del fitness será menor.

d. El número de generaciones empleadas para encontrar la solución, tiende a aumentar a medida que se aumenta el número de posibles localizaciones para antenas repetidoras, ya que en estos casos, el algoritmo tiene un mayor número de datos y situaciones sobre las que decidir qué realizar, lo que involucra un aumento en el número de generaciones necesarias para poder explorar las posibles soluciones que produzcan mejores resultados.

2. En la totalidad de las pruebas, aumenta el porcentaje de cobertura alcanzado, a medida que aumenta el número de antenas repetidoras distribuidas uniformemente.

3. Dentro de las pruebas realizadas, en las que se emplean 49 antenas repetidoras distribuidas uniformemente, se puede observar como en aquellas que se tiene 149 y 199 posibles localizaciones, se obtiene la mejor solución posible, ya que se consigue alcanzar un 100% de cobertura con un número de 49 antenas empleadas para ello, que resulta ser el mínimo número posible necesario para conseguir estas características de cubrir el 100% del territorio.

Y a continuación, se procede a mostrar los resultados obtenidos de la aplicación del fitness nuevo que fue ideado:

	Porcentaje de Cobertura	Número de antenas	Generación en la que se encontró
Prueba1: 149 0 uniformes	96,27	99	484
Prueba 2: 199 0 uniformes	98,88	94	412
Prueba 3: 249 0 uniformes	99,58	104	223
Prueba 4: 299 0 uniformes	99,99	95	219
Prueba 5: 349 0 uniformes	100	91	314
Prueba 6: 149 25 uniformes	98,45	77	201
Prueba 7: 199 25 uniformes	99,64	83	203
Prueba 8: 249 25 uniformes	99,86	75	110
Prueba 9: 299 25 uniformes	99,98	74	150
Prueba 10: 349 25 uniformes	100	78	173
Prueba 11: 149 49 uniformes	100	49	36
Prueba 12: 199 49 uniformes	100	49	51

	Porcentaje de Cobertura	Número de antenas	Generación en la que se encontró
Prueba 13: 249 49 uniformes	100	49	63
Prueba 14: 299 49 uniformes	100	49	81
Prueba 15: 349 49 uniformes	100	49	140

Tabla 2: Tabla de Resultados del Algoritmo Genético con Fitness Original en el Escenario Relajado.




Ilustración 11: Representación Gráfica Resultados Escenario Relajado con Fitness Nuevo

Tras observar todos estos resultados obtenidos, se alcanzaron las siguientes 3 ideas principales:

1. A mayor número de antenas repetidoras distribuidas uniformemente mayor cobertura se obtiene, llegando a alcanzar el 100% de la cobertura del territorio en el caso de distribuir 49 antenas uniformemente, ya que es este el mínimo número de antenas necesarias para cubrir la totalidad del territorio, siempre y cuando se distribuyan uniformemente.
2. A medida que aumenta el número de posibles localizaciones donde situar antenas repetidoras, o lo que es lo mismo, se aumenta el número de posibles antenas a colocar, aumenta de igual modo, el número de generaciones necesarias para alcanzar una solución al problema.

3. Y por último, a medida que se aumenta el número de antenas repetidoras distribuidas uniformemente, disminuye el número de éstas empleadas para conseguir dar cobertura al máximo número de localizaciones posibles.

2.3 Escenario Concreto del Proyecto

Tras el desarrollo realizado con el escenario relajado, se decidió centrarse en el estudio del nuevo escenario sobre el que se desarrolla el proyecto. En este apartado del presente documento, se procede a realizar una descripción detallada de las características de este escenario, sobre el que se ha desarrollado los algoritmos empleados en el proyecto y del que se han obtenido los resultados.

Este escenario sobre el que se ejecutarán los algoritmos bioinspirados desarrollados en el presente proyecto, es el que se encuentra descrito en el apartado “1.2 Descripción del Dominio OPLINK”, y que aquí se va a estructurar de forma más concreta. Tal y como ya se comentó, este escenario representa a la ciudad de Málaga en España (ver Ilustración 5), y se caracteriza por los siguientes aspectos:

- **Terreno:** Posee un tamaño real de 4.25 x 6.4 kilómetros, y está representado por una rejilla de 300 filas x 450 columnas.
- **Posibles Localizaciones:** Hablamos de un conjunto de 1000 posibles emplazamientos de antenas, proporcionadas a modo de coordenadas (x,y) en el fichero *mcity.txt*.
- **Antenas:** Se trabajará con antenas circulares de radio 30 celdas.
- **Fitness:** Se emplearán dos tipos de fitness para el algoritmo genético desarrollado. Estas dos funciones de fitness se corresponden con las que se habló en el apartado anterior, la original proporcionada por el problema, y una segunda función de fitness que daba mayor prioridad a la cobertura. En el caso de las colonias de hormigas, únicamente se hará uso del fitness original:

$$F = (\% \text{ cobertura})^2 / \text{número de antenas}$$

Se conoce, por estudios previos, que en este escenario, debido a los posibles emplazamientos proporcionados para situar las antenas que no cubren zonas de mar y montaña, es imposible alcanzar el 100% de cobertura en la zona. Así, la máxima cobertura que se puede alcanzar para este entorno es de un 95,79%.

Capítulo 3

Análisis y Diseño de la Aplicación

La realización de este proyecto, no incluye únicamente análisis de una serie de resultados, al igual que un estudio previo sobre el problema y sus aproximaciones anteriores, sino que involucra al mismo tiempo la elaboración de una serie de algoritmos, que serán probados y posteriormente analizados en base a sus resultados.

Por esta razón, se ha realizado una aplicación que englobase los algoritmos confeccionados para solucionar el problema concreto de diseño de redes de telecomunicación, RND. El desarrollo de esta aplicación software, ha requerido de un análisis y diseño, que se procede a describir seguidamente.

3.1 Estudio y Análisis del Problema

Se pretende realizar una aplicación software en la que poder introducir una serie de algoritmos, que en el caso de este proyecto serán bioinspirados, que den solución al problema RND de diseño de redes de telecomunicación. De la misma manera, la intención existente ante el desarrollo de esta aplicación, es que resulte fácilmente manejable por cualquier tipo de usuario, y que proporcione toda la información necesaria sobre la ejecución de los algoritmos así como de sus resultados. Puesto que el campo de estudio de este problema aún permanece ampliamente abierto, se desea que esta aplicación sea capaz de adaptarse a investigaciones futuras, y es por esta razón que la idea que guía el desarrollo de este software, es que permita futuras incorporaciones de distintos algoritmos de la forma más rápida, eficaz y sencilla posible.

Ante estas circunstancias, en primer lugar resulta necesario, establecer una serie de requisitos iniciales que guíen este desarrollo. Por tanto, los requerimientos mínimos que debe cumplir la aplicación son:

- ♦ Permitir diversos algoritmos y versiones de los mismos.
- ♦ Ofrecer facilidad para la incorporación de nuevos algoritmos.

- ♦ Ofrecer la posibilidad de realizar distintas configuraciones de un mismo algoritmo, permitiendo introducir al usuario los parámetros del mismo.
- ♦ Ofrecer una interfaz de usuario usable. Debe resultar sencilla en su manejo y atractiva al usuario.
- ♦ Los algoritmos ejecutados en la aplicación, deben generar un fichero de resultado con un formato determinado.
- ♦ La aplicación debe mostrar en su interfaz, la solución final seleccionada, con el objetivo de evitar al usuario tener que acceder al fichero, si únicamente desea visualizar la solución adoptada.
- ♦ La aplicación debe permitir seleccionar el fichero de posibles localizaciones al usuario, siempre y cuando, el fichero cumpla con el formato adecuado.

3.2 *Diseño de la Aplicación*

Tras el análisis del problema y establecer los requisitos que se desea que cumpla la aplicación que se va a desarrollar, se procede a realizar el diseño y elaboración de la aplicación que contendrá los algoritmos bioinspirados ideados para la resolución del problema de diseño de redes de telecomunicación, RND.

De este modo, y en base a los requisitos establecidos en la sección previa, en este apartado de Diseño de la Aplicación, se tratarán dos principales aspectos sobre la aplicación, con el fin de presentar las principales estrategias abordadas para cumplir estos requisitos básicos: Diseño Arquitectónico General y Diseño de la Interfaz de Usuario.

3.2.1 *Diseño Arquitectónico General.*

Atendiendo a las especificaciones de permitir la ejecución independiente de distintos algoritmos o versiones de los mismos y permitir la fácil incorporación de nuevos algoritmos sin necesidad de realizar modificaciones en la organización general del programa, la aplicación se ha definido estableciendo un diseño arquitectónico que cumpla con estas premisas.

Con el fin de crear una aplicación lo más estructurada posible, y puesto que se trata de un programa que contará con una interfaz mediante la cual invocar un determinado algoritmo de entre todos los posibles, se decidió implementar un patrón **Modelo-Vista-Controlador**. Con este patrón de diseño, se consigue una organización de los componentes de la aplicación, permitiendo mantener de forma “pseudo-independiente”, los distintos aspectos de los que se compone la aplicación: Interfaz de Usuario (Vista), Modelo y el Controlador que establece la comunicación entre las dos anteriores. A este patrón, se le ha introducido una ligera modificación, para la incorporación de los algoritmos que resuelvan el problema RND. Por tanto, tendrá un nuevo componente, Algoritmos, que encapsulará los distintos algoritmos desarrollados para resolver el problema.

La estructura general de la aplicación se puede observar en el siguiente diagrama:

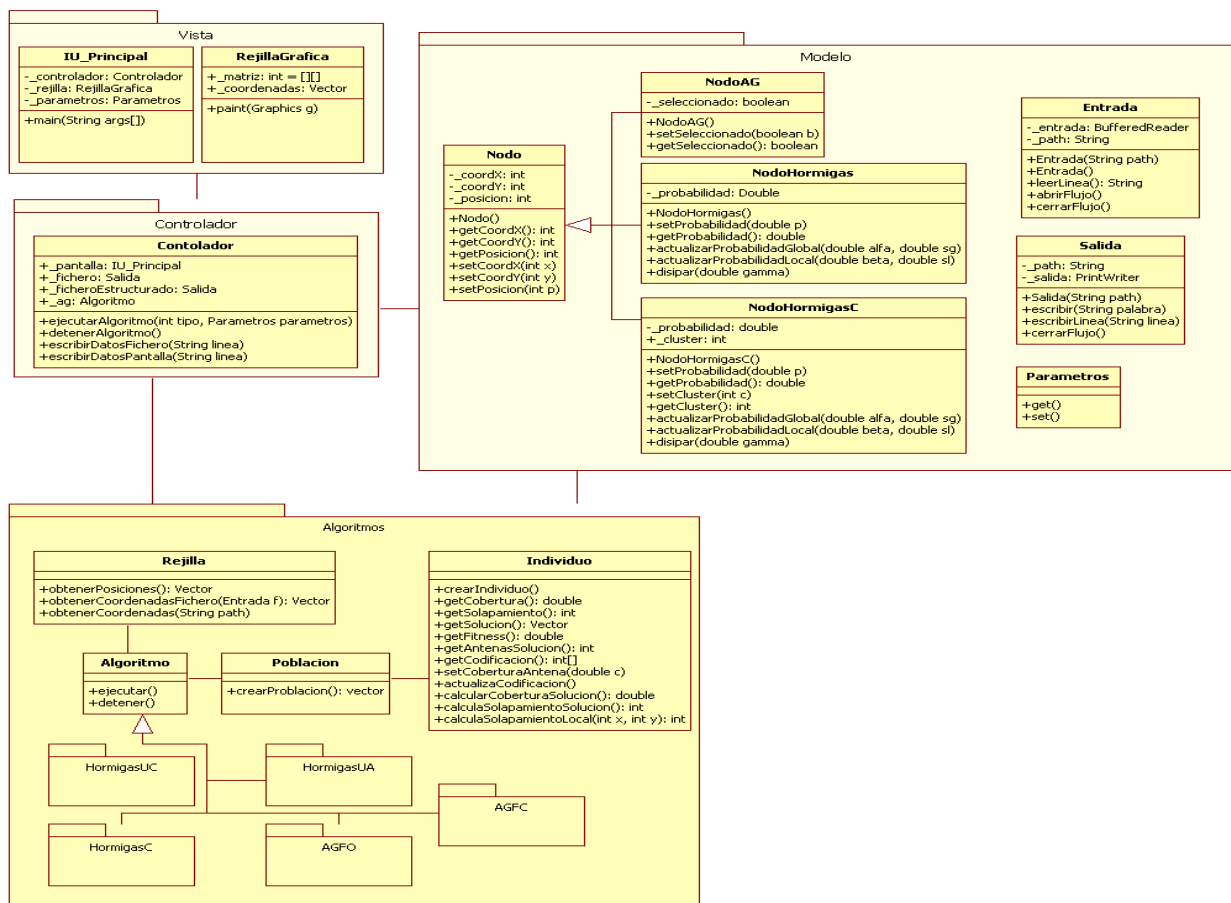


Ilustración 12: Diagrama Diseño General

De este modo, el comportamiento de la aplicación será el siguiente: todo se iniciará por orden del usuario desde el componente Vista con su interfaz gráfica, que enviará la información al Controlador de la aplicación, que será el encargado de ejecutar el Algoritmo correspondiente en base a la información recibida. Una vez que se ejecuta el algoritmo, este hará uso del componente Modelo para poder llevar a cabo su ejecución, contando con componentes que permite la escritura y lectura de ficheros de texto.

Para facilitar la inclusión de nuevos algoritmos en la aplicación se ha utilizado la idea de un patrón de diseño *Strategy*. El patrón Strategy, como bien se ha dicho, es un patrón de diseño para el desarrollo de aplicaciones software, que permite mantener un conjunto de algoritmos de los que el objeto cliente puede elegir aquel que le conviene e intercambiarlo según sus necesidades. Este patrón, define una familia de algoritmos, encapsula cada uno de ellos y los hace intercambiables entre sí, es decir, permite que el algoritmo varíe de forma independiente a quienes lo usan. La toma de decisión de emplear este patrón se debe a que entre otros factores, ayuda a sacar un factor común de la funcionalidad de los algoritmos, proporciona una alternativa a la herencia estática y ofrece distintas opciones de implementación del mismo comportamiento.

El funcionamiento de este patrón para la ejecución de los algoritmos se ilustra en la siguiente imagen, en la que se muestra la forma de relación entre las clases.

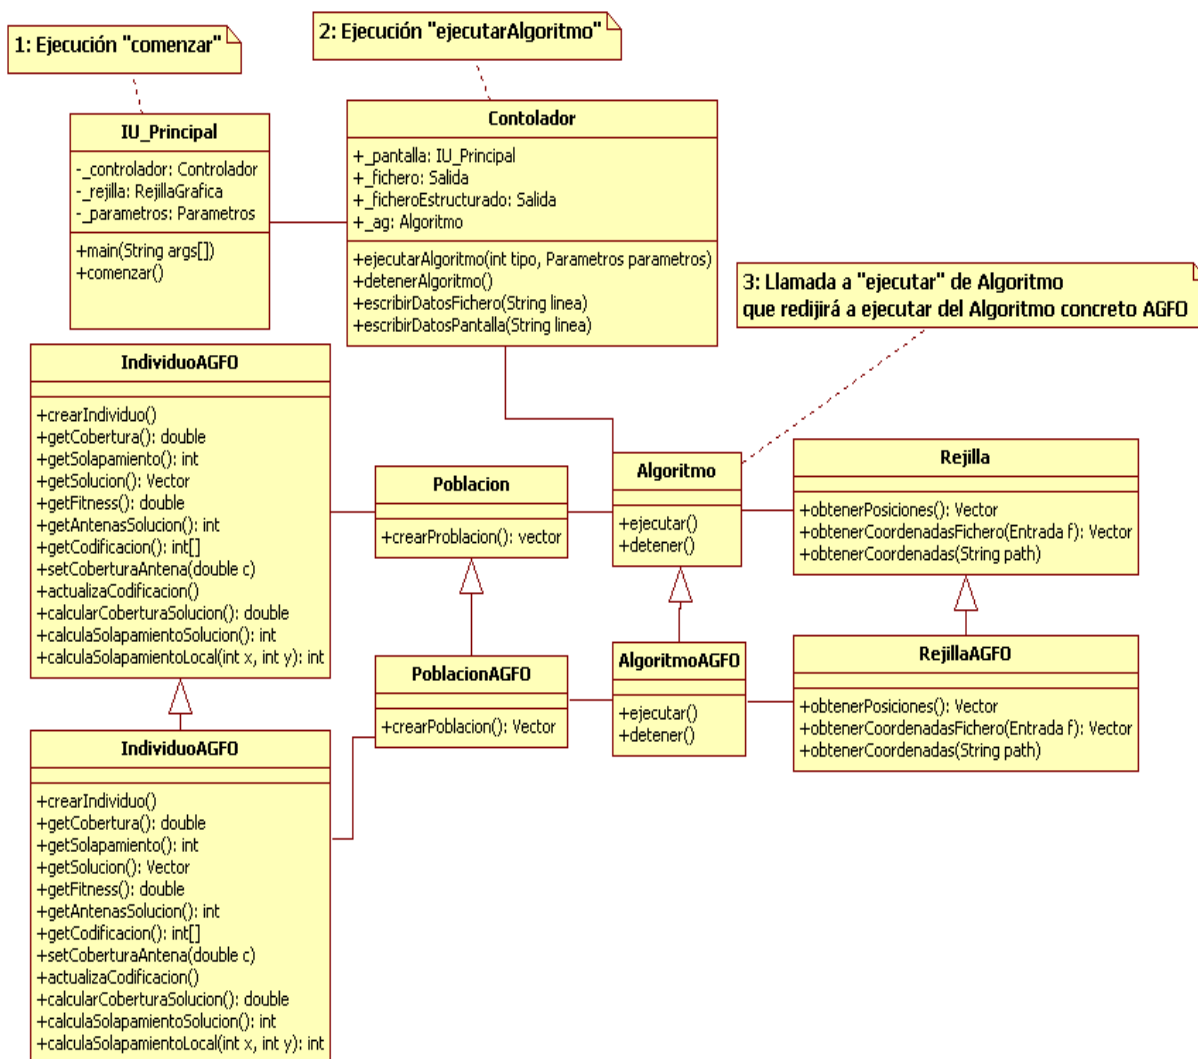


Ilustración 13: Diagrama Ejemplo Funcionamiento con “Patrón Strategy”

Si se desea en un futuro incluir algún nuevo algoritmo, simplemente será necesario seguir los siguientes pasos:

1. Crear un nuevo paquete en `PFC_RND.Source_Packages.Algoritmos.Nombre_Nuevo_Paquete`.
2. Incluir en este paquete las clases del algoritmo. Al menos deberá incluir una clave que herede de `PFC_RND.Source_Packages.Algoritmos.Algoritmo`, y que implemente los métodos ejecutar (que inicia el algoritmo) y detener (que detiene la ejecución del mismo).

3. Establecer en la clase que herede de *PFC_RND.Source_Packages.Algoritmos.Algoritmo*, un constructor de la misma que reciba como parámetros un *Controlador* y un objeto *Parámetros*. Con el objeto *Controlador*, se consigue establecer el medio de comunicación entre la interfaz y el algoritmo y con *Parámetros*, recibir toda la información necesaria para la ejecución del algoritmo. Se establece que la información se reciba con un objeto *Parámetros*, creado como clase en el paquete *Modelo*, para establecer de una forma uniforme que todos los algoritmos reciban los mismos objetos en su constructor, y conseguir de este modo, manejarlos como si fueran todos iguales.
4. Incluir en el método *ejecutarAlgoritmo* de *Controlador*, un nuevo “*case del switch*” que lance la ejecución del nuevo algoritmo.’
5. Modificar la interfaz gráfica de la aplicación, para la toma de la información del nuevo algoritmo. Incluir una nueva pestaña para los campos de los valores de los parámetros.
6. Incluir los métodos *obtenerDatosXX()*, *comenzarXX()* y *detenerXX()* para el nuevo algoritmo, siendo el primero el encargado de obtener los datos de pantalla, el segundo para dar comienzo a la ejecución del algoritmo y el último para detenerlo.

3.2.2 Información Ficheros.

Durante la fase de análisis de la aplicación, se estableció que ésta debía generar al menos un fichero estructurado definido con la información de la ejecución del algoritmo.

Atendiendo a estos requerimientos, se ha establecido que la aplicación genere dos ficheros. El primero de ellos, contiene toda la información posible acerca de la ejecución del algoritmo. Contendrá para cada generación del algoritmo, la información acerca de cobertura, antenas empeladas, solapamiento y fitness para cada individuo de la población; e incluirá al final la información de la mejor solución encontrada en todas las generaciones.

Además, la aplicación generará un segundo fichero, que tendrá un formato estructurado con el siguiente formato:

Evaluación_actual Evaluación_solución Fitnes_solución Codificación_solución

De este modo, en este fichero se escribirá la información de la mejor solución encontrada cada 25000 evaluaciones de individuos siguiendo el formato especificado anteriormente.

Estos son los ficheros que generará la aplicación con información sobre la ejecución del algoritmo, y que ofrecerán toda la información necesaria para conocer el proceder del mismo y la solución final adoptada.

3.2.3 *Diseño Interfaz de Usuario.*

Por último, en cuanto al diseño de la aplicación se refiere, se procede a describir brevemente el diseño de la interfaz. Con el propósito de cumplir con los requerimientos expuestos durante el análisis, donde se busca tener una interfaz de usuario sencilla, usable, fácilmente manejable y atractiva, se diseña la siguiente interfaz:

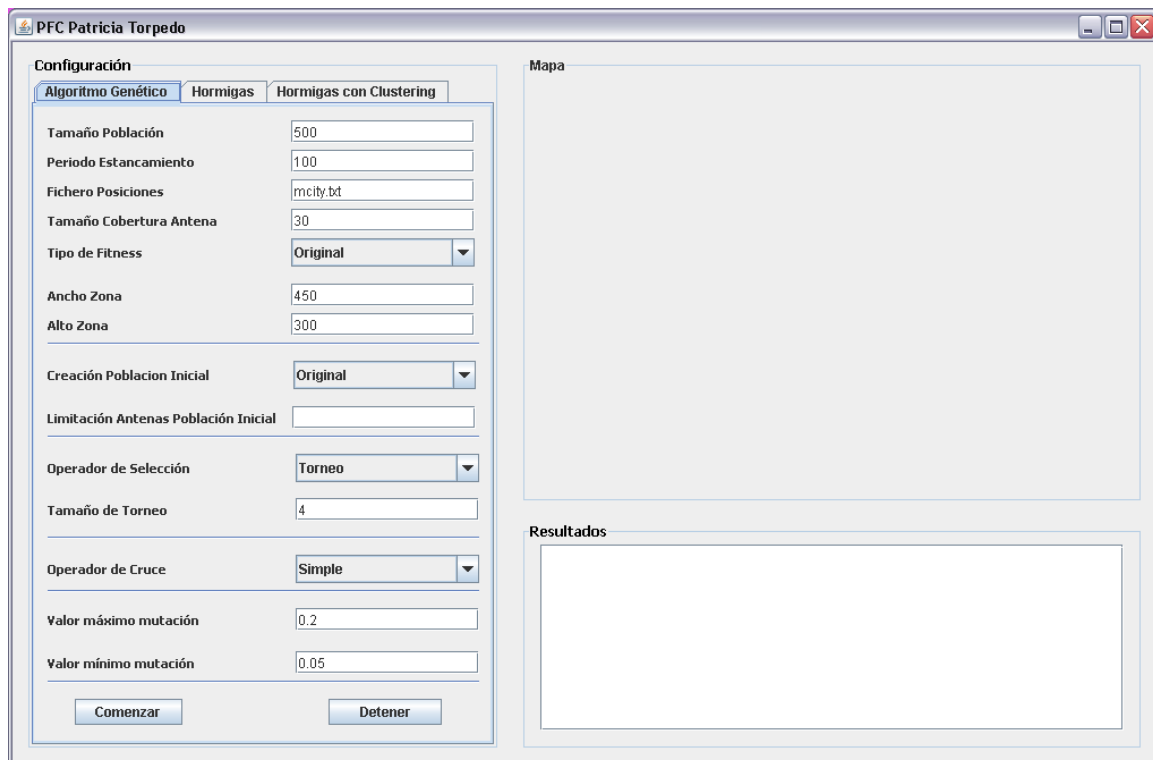


Ilustración 14: Interfaz de Usuario de la Aplicación.

Se puede apreciar tres módulos bastante diferentes a simple vista. A la izquierda de la pantalla, podemos encontrar un área destinada a la introducción de los valores de los parámetros de los algoritmos, mientras que a la derecha de la interfaz, nos encontramos con el área de muestra de los resultados, que a su vez se divide, ocupando la representación gráfica de la solución la parte superior, y su descripción textual la parte inferior. Por tanto, se puede decir que la parte izquierda de la interfaz es para introducción de información, y la derecha para la salida de información.

Ahora, centrándonos en la parte de introducción de información a la aplicación, se pueden observar en este caso 3 pestañas diferentes, cada una de ellas para cada uno de los tres algoritmos desarrollados en este proyecto.

Ilustración 15: Tres Pestañas de Configuración de los Algoritmos en la IU.

Como se puede observar, cada una de estas tres pestañas posee distintos campos, en función de los parámetros requeridos por cada uno de los algoritmos. Asimismo, se establece para cada algoritmo un botón comenzar y detener, mediante los cuales se podrá dar inicio o fin, respectivamente, a la ejecución del algoritmo.

Se ha ideado de esta forma, porque se considera que resulta más sencillo para el usuario, tener bien diferenciados los distintos algoritmos, y así conocer en cada preciso instante con qué estamos trabajando. Además, al diseñarlo de este modo, si se desea introducir un nuevo algoritmo, simplemente será necesario incluir una nueva pestaña,

sin necesidad de modificar nada de los establecidos hasta ese momento para el resto de los algoritmos.

Pasando ahora a la parte derecha de la interfaz, considerada como la de salida de información de la aplicación, simplemente destacar que en la parte superior de representación gráfica, se muestra una imagen de la rejilla, es decir, la representación del terreno para el algoritmo, en donde aparecen puntos rojos y azules y zonas amarillas y blancas.

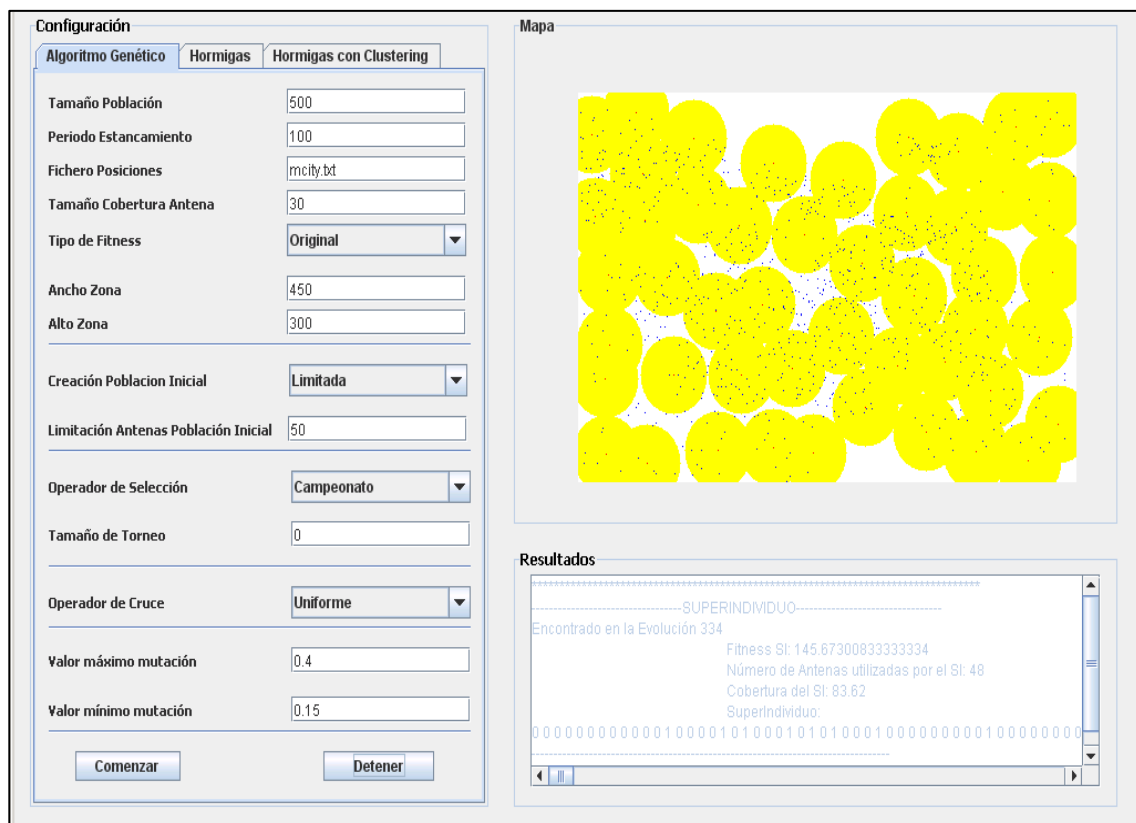


Ilustración 16: Ejemplo Representación Gráfica y Textual en Interfaz de Usuario.

Para poder entender esta representación de la solución adoptada sobre el terreno será necesario conocer la siguiente leyenda:

- ♦ *Punto Azul*: Posible emplazamiento de antena, pero en donde se ha decidido no situar ninguna.
- ♦ *Punto Rojo*: Lugar donde se ha colocado una antena.
- ♦ *Zona Blanca*: Lugar a donde no llega la cobertura.

- ♦ *Zona Amarilla:* Lugar que dispone de cobertura. Esta cobertura puede ser proporcionada por una o más antenas.

Con esto, ya se puede comprender perfectamente la solución en su representación gráfica, pero aún así, se muestra sus valores y resultados de forma textual en la parte inferior a esta representación de la solución a modo de imagen.

En cuanto a la descripción textual de la solución, se mostrará el valor de fitness de la misma, así como el porcentaje de cobertura que proporciona, el número de antenas empeladas, el solapamiento existente y su representación binaria, tal y como se puede observar en la Ilustración 18.

Durante la ejecución del algoritmo, cada cierto número de ejecuciones se va mostrando en la interfaz, la representación gráfica y textual de la solución que en ese momento se considera la mejor. De este modo, se consigue que el usuario vaya teniendo conocimiento de cómo va evolucionando la solución durante toda la ejecución, y no simplemente obtener un resultado final.

Capítulo 4

Algoritmos Empleados

4.1 Teoría General Algoritmos Genéticos.

Para ofrecer un mayor nivel de comprensión del proyecto desarrollado, se procede a describir brevemente el objetivo y funcionamiento de los algoritmos genéticos simples.

Antes de explicar el funcionamiento de los algoritmos genéticos simples, es necesario conocer la historia de cómo fueron ideados.

John Holland, fue el primero en formular la idea del algoritmo genético. Fue su anhelo por conocer cómo logra la naturaleza crear seres vivos cada vez más perfectos lo que le llevó a idear los algoritmos genéticos, tratando de hacer pequeños modelos de la naturaleza, que tuvieran alguna de sus características, y ver cómo funcionaban, para luego extrapolar sus conclusiones a la totalidad.

Fue a principios de los años 60, cuando sus ideas comenzaron a desarrollarse y dar frutos, a partir de lecturas de libros como “La teoría genética de la selección natural”, de R. A. Fisher, con los cuales aprendió que la evolución era una forma de adaptación más potente que el simple aprendizaje, y tomó la decisión de aplicar estas ideas extraídas de sus lecturas, para el desarrollo de programas bien adaptados para un objetivo determinado.

Durante el curso que Holland impartía en la Universidad de Michigan, sobre la Teoría de sistemas adaptativos, y con las aportaciones de sus estudiantes, creó las ideas que más tarde se convertirían en los algoritmos genéticos que conocemos en la actualidad.

Unos 15 años más tarde, David Goldberg, ingeniero industrial, conoció a Holland y sus investigaciones y decidió aplicar sus ideas para resolver el diseño de pipelines, creando un algoritmo genético. Esta y otras aplicaciones creadas por estudiantes de Holland convirtieron a los algoritmos genéticos en un campo de estudio con base suficiente, cuyo uso perdura en el tiempo hasta nuestros días.

Conociendo ya, un poco de la historia de los algoritmos genéticos, nos adentramos ahora en conocer que son exactamente los algoritmos genéticos y cómo funcionan.

Un algoritmo genético es un método de búsqueda dirigida basada en probabilidad. En otras palabras, los algoritmos genéticos son métodos sistemáticos para la resolución de problemas de búsqueda y optimización que aplican los mismos métodos de la evolución biológica: selección basada en la población, reproducción sexual y mutación.

Los algoritmos genéticos establecen una analogía entre el conjunto de soluciones de un problema (fenotipo) y el conjunto de individuos de una población, cada uno de los cuales se encontrará codificado mediante una cadena, generalmente binaria (cromosoma). Los símbolos que forman cada cromosoma, reciben el nombre de genes.

Estos cromosomas, evolucionarán a través de las iteraciones del algoritmo genético, llamadas generaciones. En cada generación, los cromosomas son evaluados según su calidad y aptitud.

Hay que tener en cuenta, que un algoritmo genético es independiente del problema, lo cual hace que sea un algoritmo robusto. No obstante, y aunque puede ser útil para cualquier problema, resulta un algoritmo débil, pues no está especializado en resolver ningún problema en concreto.

Para aplicar un algoritmo genético es necesario realizar dos tareas o fases principales: Codificación del problema y Funcionamiento del Algoritmo Genético.

A continuación, se procede a explicar cada una de estas fases:

a) CODIFICACIÓN DEL PROBLEMA

Como ya se ha comentado anteriormente, los algoritmos genéticos requieren que el conjunto de la información que conlleva cada individuo se codifique en un cromosoma. Cada uno de estos cromosomas posee varios genes, que corresponden a cada uno de los parámetros del problema. Para poder trabajar con estos genes en el ordenador, es necesario codificarlos como una cadena de símbolos, generalmente símbolos binarios (1's y 0's).

En la mayor parte de las ocasiones, una buena codificación es la clave de una buena resolución del problema. Una condición indispensable que debe cumplir toda codificación para que esto sea verdad, es la llamada regla de los bloques de construcción, que establece que los parámetros relacionados entre sí deben de estar

cerca en el cromosoma, para que de este modo, una variación pequeña en el mismo, no involucre un gran cambio en el fenotipo correspondiente.

b) FUNCIONAMIENTO DEL ALGORITMO GENÉTICO

Todo algoritmo genético procede del siguiente modo:

En primer lugar, se genera de forma aleatoria la población inicial de individuos, la cual estará constituida por un conjunto de cromosomas que representarán posibles soluciones del problema.

A continuación, a cada uno de los cromosomas de la población generada, se le aplicará una función de aptitud ("*función fitness*"), que medirá cómo de buena es la solución que el individuo está codificando.

Una vez que se conoce la aptitud de cada individuo, se elige los individuos que serán cruzados para obtener la siguiente generación, siendo los de mayor aptitud, los que poseen mayor probabilidad de ser seleccionados.

Se aplica el operador de cruzamiento. Este operador es el principal operador genético, y representa la reproducción sexual. El cruzamiento opera sobre dos individuos a la vez para generar dos descendientes, los cuales heredan las características de los individuos padres que los han generado.

Tras aplicar este operador, se pueden dar otros como la mutación, que altera, con cierta probabilidad, el valor de algunos genes del individuo.

Aplicados ya los operadores del algoritmo, éste deberá detenerse cuando se alcance la solución óptima buscada, o bien cuando se alcance un número de generaciones preestablecido o no existan cambios en la población de una generación a otra.

Cada uno de estos pasos involucra una actuación sobre la cadena de bits codificada. A cada uno de estos operadores, se les denomina operadores genéticos, y como se puede deducir del esquema anterior existen tres principales: selección, cruzamiento y mutación.

Todo algoritmo genético, además de poseer una serie de operadores genéticos, requiere también una serie de parámetros que resulta necesario fijar para cada ejecución, como son los siguientes:

- **Tamaño de la población:** Establece el número de individuos que constituyen cada población, sobre la cual trabajará el algoritmo genético en cada generación. Este número debe ser suficiente para garantizar la diversidad de las soluciones.
- **Condición de parada del algoritmo:** Establece cuando el algoritmo debe parar su ejecución. Lo más habitual es que la condición de parada del algoritmo sea la convergencia del algoritmo genético o un número preestablecido de generaciones.

Una vez explicado el funcionamiento general de todo algoritmo genético, se procede a describir de forma más detallada cada uno de los operadores genéticos que usa todo algoritmo genético.

○ **Operador de Selección:**

Como ya se ha mencionado previamente en este documento, los individuos de la población sobre los que trabaja el algoritmo genético se seleccionan para reproducirse. Ahora bien, el problema surge cuando hay que decir cómo seleccionar los individuos que van a cruzarse posteriormente. De acuerdo a la teoría de la evolución de Darwin, únicamente los mejores individuos y los más adaptados al ambiente se reproducen. Es en este principio en el que se basa el operador de selección de los algoritmos genéticos, tal y como se conocen hoy en día. Existen tres principales tipos de selección: ***Selección por Ruleta, Selección Ruleta con Ranking o Jerárquica y Selección por Torneo.***

• **Selección por Ruleta**

Los individuos padres, se seleccionan de acuerdo a su valor de fitness. Por tanto, los mejores individuos serán los que tengan mayores probabilidades de ser elegidos.

A cada individuo, se le asigna una probabilidad de acuerdo a su valor de fitness. Intuitivamente el proceso construye una ruleta o un "tarta" en la que cada uno de las porciones representa a un individuo. La porción de tarta que le toca a cada individuo es proporcional a su fitness. Así los individuos buenos se llevarán las mayores porciones y al revés ocurrirá con los peores.

A continuación se muestra un ejemplo de cómo resulta este operador:




Ilustración 17: Ejemplo ilustrativo del funcionamiento del operador de selección por ruleta.

Este operador de selección por ruleta, tiene dos variantes, la primera de ellas, es el ejemplo anterior, y su funcionamiento se refleja con el algoritmo siguiente:

- Calcular la suma total acumulada de los fitness de todos los individuos de la población actual.
- Generar un número aleatorio entre 0 y la SumaTotal (“r”).
- Recorrer la población acumulando nuevamente los fitness. Cuando la suma que se contabilice sea mayor o igual a r seleccionamos el individuo donde se vaya recorriendo.

Sin embargo, este tipo de selección tiene un mal comportamiento en los casos en los que existen grandes diferencias entre los fitness de los individuos de la población. Por ejemplo, si un individuo ocupa el 90% de la ruleta el resto de los individuos de la población tienen muy pocas posibilidades de ser elegidos. Una solución a este problema es la segunda variante de la selección por Ruleta, Selección por Ranking.

• Selección por Ruleta con Ranking o Jerárquica

Los individuos son ordenados de acuerdo a su ranking de fitness. De esta manera si tenemos “n” cromosomas el individuo con peor fitness se le asignará un 1 y el que tenga el mejor fitness se le asignará la n.

Observemos ahora la representación gráfica de ambas variantes juntas:




Ilustración 18: Ejemplo ilustrativo variante operador de selección por ruleta sin ranking.




Ilustración 19: Ejemplo ilustrativo variante operador de selección por ruleta con ranking.

Ahora todos los cromosomas tienen la oportunidad de ser seleccionados. Sin embargo este método puede hacer que el genético converja lentamente a la solución, ya que los mejores individuos no se diferencian apenas de los peores.

• Selección por Torneo

La selección por Torneo K/L consiste en seleccionar K individuos de la población de manera aleatoria y de estos K individuos se seleccionan los L que tengan mejor fitness. Este proceso se repite todas las veces necesarias hasta formar la nueva población.

Este es uno de los métodos de selección más utilizados actualmente. Se emplea también en algunos algoritmos en el momento de la aceptación.

○ **Operador de Cruzamiento:**

El operador de cruce genera dos nuevos hijos a partir de dos cadenas padre recombinando sus bits. Para elegir con que bits contribuye cada padre hacemos uso de una “máscara de cruce”.

Consiste en el intercambio de material genético entre dos cromosomas. El cruce es el principal operador genético, hasta el punto que se puede decir que no es un algoritmo genético si no tiene cruzamiento y, sin embargo, puede serlo perfectamente sin mutación.

Para aplicar el cruce, se escogen aleatoriamente dos miembros de la población. No pasa nada si se emparejan dos descendientes de los mismos padres; ello garantiza la perpetuación de un individuo con buena puntuación. Sin embargo, si esto sucede demasiado a menudo, puede crear problemas, ya que toda la población puede aparecer dominada por los descendientes de algún gen que, además puede tener caracteres no deseados.

Existen tres tipos de operadores de cruzamiento:

▪ **Cruce Simple:**




Ilustración 20: Ejemplo Cruce Simple.

▪ **Cruce Multipunto:**




Ilustración 21: Ejemplo Cruce Multipunto.

- **Cruce Uniforme:**




Ilustración 22: Ejemplo Cruce Uniforme.

- **Operador de Mutación:**

El operador de mutación produce un nuevo hijo de un solo padre cambiando el valor de uno de sus bits elegido al azar. Generalmente se aplica después de hacer uso del operador cruce:




Ilustración 23: Ejemplo Operador Mutación.

En la Evolución, una mutación es un suceso bastante poco común. En la mayoría de los casos las mutaciones son letales, pero en promedio, contribuyen a la diversidad genética de la especie. En un algoritmo genético tendrán el mismo papel, y la misma frecuencia (es decir, muy baja).

Una vez establecida la frecuencia de mutación, por ejemplo, uno por mil, se examina cada bit de cada cadena cuando se vaya a crear la nueva criatura a partir de sus padres. Si un número generado aleatoriamente está por debajo de esa probabilidad, se cambiará el bit (es decir, de 0 a 1 o de 1 a 0). Si no, se dejará como está. Dependiendo del número de individuos que haya y del número de bits por individuo, puede resultar que las mutaciones sean extremadamente raras en una sola generación.

No hace falta decir que no conviene abusar de la mutación. Es cierto que es un mecanismo generador de diversidad, y, por tanto, la solución cuando un algoritmo genético está estancado, pero también es cierto que reduce el algoritmo genético a una búsqueda aleatoria. Siempre es más conveniente usar otros mecanismos de generación

de diversidad, como aumentar el tamaño de la población, o garantizar la aleatoriedad de la población inicial.

Con esta información, ya se conoce todo lo necesario para comprender a la perfección el desarrollo del proyecto en lo referente a la teoría de los algoritmos genéticos.

4.2 Descripción Algoritmos Genéticos Desarrollados.

Una vez descrito el funcionamiento general de los algoritmos genéticos, se va a describir el algoritmo genético concreto desarrollado.

Como primera propuesta para afrontar la resolución del problema RND dentro del escenario detallado en capítulos anteriores, se ha diseñado un Algoritmo Genético (AG). Como ya se ha comentado, un AG es un método de búsqueda dirigida basada en probabilidad, es decir, son métodos sistemáticos para la resolución de problemas de búsqueda y optimización que aplican los mismos métodos de la evolución biológica: selección basada en la población, reproducción sexual y mutación, en donde se seleccionan los mejores individuos en base a un valor fitness. Este valor viene dado por una función que determina cuales son los individuos más adaptados.

Ante esto, se pueden identificar ya una serie de puntos básicos a tener en cuenta en la elaboración del algoritmo genético. Para el desarrollo del Algoritmo Genético que se presenta en este proyecto, se han definido una serie de fases, que coinciden con el funcionamiento general de estos algoritmos, pero que se han adecuado en concreto para este problema. Las etapas de este algoritmo genético son:



Ilustración 24: Fases del AG.

Con esta imagen, se representa a la perfección el comportamiento que sigue el algoritmo, y para aportar más detalle sobre cada una de ellas, a continuación se describe las decisiones y métodos aplicados. Sin embargo, antes de comenzar a describir cada una de las etapas, es necesario especificar cómo se ha abordado una de las fases fundamentales a la hora de diseñar un algoritmo genético: ***La Representación o Codificación de los Individuos.***

La codificación que se elige para representar a los individuos de la población, y por tanto a la posible solución, es uno de los factores más importantes para asegurar el correcto desempeño del algoritmo. Una mala codificación de la solución, puede provocar que el algoritmo no funcione correctamente, o si lo hace, si se escoge una codificación demasiado compleja, puede hacer que la ejecución del algoritmo sea demasiado lenta, y por tanto no sea eficaz utilizarlo.

Inicialmente, podría pensarse en que cada individuo representase la totalidad de la rejilla (terreno) indicando en cada celda un 0 si no existe antena en esa posición, y un 1

en caso de que sí se haya colocado antena. Sin embargo, puede verse rápidamente que esto resulta totalmente innecesario además de contraproducente, ya que sabemos que en la mayoría de localizaciones de la totalidad del terreno es imposible colocar una antena, y con esta codificación, estaríamos ante una situación en la que sería prácticamente imposible manejar tal cantidad de datos para cada individuo de la población.

Atendiendo a estos aspectos, y a las características del problema, se estableció el diseño o estructura que tendrían los individuos. Se pensó, que ya que, se trataba de decidir si en ciertas posiciones se iban a colocar o no antenas, y que la lista de posibles localizaciones se proporcionaba de antemano al algoritmo, se podría representar el individuo como una lista de N bits, siendo N el número de posibles emplazamientos de antenas, donde cada uno de los bits tomaría un valor 1 o 0, dependiendo de si en esa localización existe o no antena.

Se trata por tanto, de una representación binaria de la siguiente forma:

1	0	0	0	1	1	0	0	0	0	1	...	0	1	0
---	---	---	---	---	---	---	---	---	---	---	-----	---	---	---

Ilustración 25: Ejemplo Representación Individuo en AG.

De este modo, y una vez que se conoce como se representa cada uno de los individuos de la población, se describen la forma de acometer cada una de sus fases:

- **Creación de la Población:** La primera etapa de todo algoritmo genético es la creación de la población inicial de individuos. Este proceso, se realiza solamente una vez durante toda la ejecución del algoritmo, y tiene una gran influencia en el posterior desarrollo, ya que dependiendo de cómo de buena sea esta inicialización, resultará más o menos complicado obtener después una buena solución final.

Hablando en términos generales de los algoritmos genéticos, esta creación inicial de los individuos de la población debe realizarse de forma aleatoria. Así, en el caso del algoritmo que aquí se trata, y teniendo en cuenta la codificación elegida para representar a un individuo, durante este proceso lo que se hará es establecer de forma pseudo-aleatoria para cada una de las

posiciones de cada individuo si tendrá o no antena, es decir, si será un 0 o un 1.

Para esta primera fase del algoritmo, se han ideado y desarrollado dos métodos de creación de población inicial. El primero de ellos, simplemente se encarga de recorrer cada una de las posiciones que representan una posible localización para cada individuo, estableciendo de forma aleatoria si hay o no antena.

Sin embargo, tras la realización de algunas pruebas, que ya se comentarán en el capítulo correspondiente del presente documento, se observó que con esta inicialización al algoritmo le costaba un poco alcanzar una buena solución. Por esta razón, se pensó en un segundo método de creación de la población.

Este segundo método funciona del mismo modo que el primero, simplemente se encarga de determinar de forma aleatoria si habrá o no antena en cada una de las posiciones que representan al individuo. Sin embargo, en este caso se establece un limitador del posible número de antenas a utilizar en esta primera población. Así, con este método, simplemente se genera N números aleatorios que estén comprendidos en $[0, M]$, siendo N el número limitador que establece el máximo de antenas a situar para cada individuo de la población inicial, y M el número máximo de posibles localizaciones de antenas, es decir, el tamaño de la codificación binaria del individuo. De este modo, se consigue que el algoritmo encuentre más fácilmente una buena solución final, ya que si por ejemplo, como es el caso de este estudio, tenemos 1000 posibles posiciones, el algoritmo no tendrá que reducir antenas de esas 1000 sino que tendrá que reducir o aumentar del valor N que se establezca.

- **Evaluación de los Individuos de la Población:** En lo referente a la evaluación de los individuos, destacar que se lleva a cabo antes de ejecutar cualquiera de los operadores. Este proceso, se realiza con el fin de conocer como de adaptado se encuentra cada individuo en referencia a la solución óptima, así como para ir conociendo a lo largo de las generaciones, cual es el mejor individuo.

En el caso del algoritmo genético ideado, se han desarrollado dos funciones de fitness diferentes. La primera de ellas se corresponde con la fórmula que ya se ha citado y explicado previamente, cuando se hablaba en el primer capítulo del presente documento del problema RND y del dominio OPLINK. Recordándolo, esta función de fitness sigue la siguiente fórmula:

$$F = (\% \text{ cobertura})^2 / \text{número de antenas}$$

Con este ***Fitness Original***, se consigue establecer una relación entre el porcentaje de cobertura que proporciona la solución adoptada por el individuo, y el número de antenas empleado para conseguir dicha cobertura. Así, con esta fórmula se consiguen cubrir ambos objetivos de manera eficaz.

Con el fin de innovar y probar nuevas posibilidades, se decidió dar forma a una nueva función de fitness, ***Fitness por Cobertura***. Se pensó, que quizás en algunos casos resultase más conveniente conseguir el máximo valor de cobertura, a pesar de que eso supusiera emplear algunas antenas más para lograrlo. Ante este pensamiento inicial, se decidió establecer una nueva forma de evaluar a los individuos de la población.

En primer lugar, se establece un nuevo parámetro al algoritmo, que será constante y que determina el porcentaje o margen de cobertura permitido. Esto es así, ya que con esta nueva función, se establece que un individuo es mejor, si su porcentaje de cobertura es mayor, o bien es menor dentro de un margen dado y utiliza menor número de antenas. Es decir, si establecemos un margen de cobertura de 2%, por ejemplo, un individuo es mejor que otro si simplemente proporciona mayor cobertura, o bien proporciona como mucho un 2% menos de cobertura que el otro y utiliza para ello menor cantidad de antenas.

- **Operador de Selección:** En cuanto al operador de selección que se utilizará en este algoritmo genético, destacar que se han desarrollado dos métodos para llevarlo a cabo, que podrán ser seleccionados directamente por el usuario de la aplicación a través de la interfaz de usuario.

El primer método desarrollado para realizar la selección de individuos de la población, ha sido el **Torneo**, que ya fue descrito en el apartado anterior, cuando se hablaba de la teoría general de los AG. Como ya se comentó, la selección por Torneo K/L consiste en seleccionar K individuos de la población aleatoriamente y de estos K individuos se seleccionan los L que tengan mejor fitness. La determinación del valor de K, también será trabajo del usuario de la aplicación, que lo introducirá mediante la interfaz gráfica de la aplicación. En el caso del **Torneo** que se ha desarrollado, se selecciona aleatoriamente K individuos, y de estos K individuos, pasará a la población de seleccionados únicamente aquel individuo de mejor valor fitness.

Con el firme propósito de realizar un algoritmo lo más completo y diverso posible, se ha desarrollado otro mecanismo de selección, al que se le ha denominado **Campeonato**. Este nuevo método consiste en recorrer todos y cada uno de los individuos de la población, ya que todos entran en la competición, y enfrentarlos de dos en dos pasando a la siguiente fase el mejor de cada par. De este modo, en la siguiente fase se enfrentarán de nuevo de dos en dos, aquellos individuos que resultaron ganadores de la anterior fase. Cada elemento que gana, se introduce en la población intermedia; de este modo los mejores individuos abundarán más en la nueva población. En el caso en el que haya un individuo sin tener con quien competir, competirá con el individuo que tiene delante en la población, a pesar de que este último compita dos veces en una misma fase.

- **Operador de Cruce:** Al igual que el operador de selección, para el operador de Cruce se han desarrollado dos métodos para su posible ejecución: **Simple** y **Uniforme**. El funcionamiento de ambos métodos puede verse en la teoría de algoritmos genéticos del apartado anterior, pero resumiéndolo, el **cruce simple** se basa en seleccionar dos individuos, a los que se llamará padres, que serán partidos por la mitad y que formaran dos nuevos individuos, denominados hijos, uno de los cuales estará formado por la primera mitad del padre1 y la segunda mitad del padre2, y el segundo de los hijos estará formado por la primera mitad del padre2 y la segunda mitad del padre1. En cuanto al **cruce uniforme**, se seleccionan dos padres de la población actual, y los hijos se obtendrán como el resultado de sus padres, es decir, el hijo1

será como el padre1 y el hijo2 será como el padre2, salvo intercambios de alelos entre ellos. Es decir, para este método, se establece un valor de probabilidad de intercambio de alelo. Entonces, para cada alelo, en base a esa probabilidad se decide si se cambia su valor de bit por el del otro padre. Esto se entiende a la perfección, observando la Ilustración 24.

Destacar que no se hace uso de elitismo, y que todos los individuos de la nueva población vendrán dados por cruzamiento entre dos individuos de la población intermedia.

- **Operador de Mutación:** Y por último, el operador de mutación. Para la ejecución del operador de mutación se ha ideado un método basado en unos porcentajes máximo y mínimo. La aplicación de la mutación se hace a nivel de alelo de forma general a la población. Para ello, se establecen dos nuevos parámetros, que ayudarán a establecer el número de alelos de la totalidad de la población que van a ser mutados. Ante esta situación, lo que se hace es introducir como parámetro al método dos valores, un porcentaje máximo y un porcentaje mínimo de mutación. Con estos valores, se genera un valor aleatorio que esté incluido entre ambos, y que proporcionará el valor entero de alelos de la población a mutar. Tras esto, simplemente se selecciona de forma aleatoria N alelos para ser mutados de la siguiente forma: se selecciona al azar un individuo de la población, y posteriormente se vuelve a seleccionar al azar uno de sus alelos, repitiendo este proceso hasta conseguir mutar los N alelos.

Este tipo de mutación, surgió de la idea de conseguir un mecanismo rápido y eficaz, para no tener que ir alelo por alelo de todos los individuos de la población para aplicar la mutación. Con este método se consigue mayor rapidez de ejecución y por tanto más eficacia, ya que al final, el resultado de la mutación es básicamente el mismo.

Los parámetros de configuración necesarios para la ejecución del algoritmo son:

- ♦ *Tamaño de la Población:* Establece el número de individuos que existirán en la población.

- ♦ *Periodo de Estancamiento:* Indica el número de generaciones máximas a ejecutar antes de detener la ejecución del algoritmo, durante las cuales no se produzca cambios en la elección del mejor individuo.
- ♦ *Limitación Antenas Población Inicial:* En el caso de optar por la creación de la población inicial mediante el método de limitación de antenas, será necesario especificar el número máximo de antenas permitido.
- ♦ *Valor máximo y mínimo de mutación:* Estos valores establecen el porcentaje máximo y mínimo para obtener el número de alelos a mutar.
- ♦ *Tamaño del Torneo:* En caso de elegir como operador de selección el Torneo, será necesario especificar el tamaño de dicho torneo, es decir, el número de individuos que competirán cada vez.

En cuanto a los referente a estos parámetros de configuración del algoritmo, tales como el tamaño de población, porcentajes máximos y mínimos de mutación, tamaño del torneo, incluso la selección del tipo de operador en cada caso, como puede ser Campeonato o Torneo en la Selección, o Uniforme o Simple en el Cruce, son todos configurables por el usuario mediante la interfaz de usuario de la aplicación.

4.3 Teoría Optimización con Colonia de Hormigas.

La observación de la naturaleza ha sido una de las principales fuentes de inspiración para la propuesta de nuevos paradigmas computacionales. De esta forma, nacieron diversas técnicas de Inteligencia Artificial, como los algoritmos genéticos, de los que ya se ha hablado, Redes Neuronales y entre estas técnicas, el sistema basado en Colonias de Hormigas, que se tratará a continuación.

En esta área de Optimización mediante Colonias de Hormigas, se estudian sistemas artificiales que simulan el comportamiento de colonias de hormigas reales, de donde toman su inspiración. Estos sistemas son utilizados para resolver problemas de optimización combinatoria, los cuales pueden ser descritos como problemas cuyo objetivo es encontrar la secuencia óptima de sus elementos componentes.

Dentro de esta área, se encuentra el Ant System (AS), que es el primer algoritmo desarrollado dentro de este campo. Se basa en el comportamiento colectivo de las hormigas en la búsqueda de alimentos para subsistir.

Como puede observarse, todos estos algoritmos, tendrán una fuerte inspiración biológica, que se procede a describir seguidamente, para facilitar la comprensión de estos algoritmos.

Resulta fascinante como las hormigas son capaces, siendo animales casi ciegos, de encontrar el camino más corto desde el hormiguero a una fuente de alimento y viceversa sin usar pistas visuales, moviéndose prácticamente al azar. Asimismo, son capaces de adaptarse a cambios en el ambiente.

El medio por el que las hormigas logran esto, es por rastreo de la feromona que ellas mismas depositan mientras caminan. En la naturaleza, las feromonas desempeñan un papel muy importante en la organización y supervivencia de muchas especies, constituyendo un sistema de comunicación química entre los animales de una misma especie, que transmiten información a través de señales odoríferas sobre su estado, edad, sexo, etc., que son recibidas por el animal receptor, quien las interpreta.

Todas las hormigas depositan cierta cantidad de esta sustancia denominada feromona mientras caminan, y a su vez, cada hormiga prefiere caminar en una dirección rica en feromona. Esta conducta aparentemente tan simple, explica el porqué son capaces de ajustarse a cambios en el ambiente, ya que si por ejemplo, un obstáculo

inesperado es colocado en el camino que las hormigas están utilizando en ese momento, las hormigas que están justo enfrente del obstáculo no pueden continuar siguiendo el rastro de feromona y por tanto, deben elegir si ir por la derecha o por la izquierda de dicho obstáculo. Esta elección que realiza la hormiga sobre qué nuevo camino seguir es aleatoria; cada hormiga decide al azar hacia donde irse, aunque es de esperar por probabilidades, que el 50% de ellas se decante por la derecha, y el otro 50% por la izquierda. De este modo, las hormigas que aleatoriamente eligieron el camino más corto, crearán en un cierto periodo de tiempo un depósito de feromona más fuerte que el de las hormigas que eligieron el otro camino, debido a que las que eligieron el camino más corto, llegan al otro lado más rápido y repiten el camino más veces. De esta forma, pasaran más hormigas por el camino más corto, y habrá por tanto más feromona depositada en esa ruta, lo que provocará que las que vienen detrás, seleccionen esta ruta, restableciéndose de este modo el camino más corto entre el hormiguero y la fuente de comida.

Este comportamiento de las hormigas, puede entenderse fácilmente observando la siguiente imagen, en la que se muestra todo lo explicado antes:




Ilustración 26: Comportamiento Adaptativo de las Hormigas.

Resumiendo, en un principio, una hormiga aislada se mueve esencialmente al azar, pero las siguientes deciden con una buena probabilidad seguir el camino con mayor cantidad de feromonas. Esta técnica de las hormigas para establecer el camino más corto ha inspirado estos novedosos algoritmos aplicables a muchos problemas.

Inspirados en el comportamiento de las hormigas, Dorigo propone en [30] el algoritmo Ant System, que ya se citó con anterioridad. En este documento, Dorigo propone un nuevo algoritmo de búsqueda cooperativo inspirado en la conducta de hormigas reales. Esta conducta, es imitada por el algoritmo usando agentes sencillos, en este caso denominados hormigas, que se comunican indirectamente por medio de un mecanismo inspirado en el rastro de feromonas. En su representación algorítmica, estos rastros de feromonas artificial, son un tipo de información numérica distribuida que es modificada por las hormigas y refleja su experiencia en la solución de un problema concreto.

Tres son las principales ideas que se tomaron de la naturaleza para este algoritmo: 1) Se utiliza comunicación indirecta mediante las feromonas; 2) Las rutas más cortas tienden a tener una razón más alta de crecimiento del valor de la feromona; y 3) Las hormigas tienen preferencia de forma probabilística por las rutas con mayor valor de feromona.

Además de estas ideas, se introdujeron al algoritmo otra serie de capacidades que no tienen las hormigas reales, pero que facilitaban de forma considerable la resolución de los problemas. Estas otras ideas son: 1) Cada hormiga es capaz de determinar cómo de lejos se encuentra de un estado; 2) Las hormigas poseen información sobre su ambiente y lo utiliza para la toma de decisiones; y 3) Las hormigas tienen memoria, lo que resulta necesario para asegurar que se generan únicamente soluciones factibles.

Originalmente este algoritmo fue ideado para dar solución al problema del viajero, en donde se consideran un conjunto de ciudades que deben ser visitadas una sola vez con el objetivo de encontrar el recorrido mínimo.

A partir de este primer algoritmo, se han propuesto varias extensiones o versiones del mismo:

- *Algoritmo Ant-Q*: Híbrido del algoritmo Ant System con aprendizaje-Q.
- Nuevas versiones de híbridos de Ant Colony Optimización con búsquedas locales.
- *MAX-MIN Ant System*: Únicamente permite actualizar los rastros de feromona a la mejor hormiga en cada ciclo y se establecen valores máximos y mínimos de acumulación de feromona.

- *Ant Colony System (ACS)*: Se trata de una extensión del Ant-Q.

En cuanto a las posibles aplicaciones de estos algoritmos, cabe destacar que, además de emplearse para el problema del viajero, se han empleado también para el Ruteo de Vehículos, Problema de Flujos de Procesos y MOAQ, que es un algoritmo para la optimización de redes de irrigación, entre otras.

4.4 Descripción Algoritmo de Colonias de Hormigas Desarrollado.

El segundo algoritmo propuesto para dar solución al problema RND y que se presenta en este proyecto, es un sistema de colonias de hormigas. Como se ha comentado previamente, los sistemas de colonias de hormigas son algoritmos muy buenos para resolver problemas de optimización, y es por esta razón por la que se ha decidido desarrollar este algoritmo para este estudio. Además, se trata de un algoritmo poco investigado en el área del problema RND, lo que provoca que resulte más atractivo.

Originalmente los sistemas de colonias de hormigas son utilizados para resolver problemas para encontrar el camino óptimo. Sin embargo, en el caso que nos ocupa, el problema RND no es un problema que trate de encontrar un camino mínimo, ya que en ese caso lo que se buscaría es encontrar el camino mínimo visitando todas las posibles localizaciones de antenas, y ese no es el fin que se está buscando. Por este motivo, y ya que se pretende únicamente encontrar la combinación de posiciones, para colocar antenas que mayor cobertura proporcione, ha sido necesario adaptar el algoritmo para que consiga resolver correctamente el problema. En este caso, no se intenta minimizar distancias recorridas ni problemas parecidos, por ello, en realidad, no importa qué posición visite una hormiga después de estar en otra, sino que simplemente es necesario conocer las posiciones visitadas, con independencia del orden del recorrido.

Ante esta situación, se establece para el algoritmo que, cada una de las posibles localizaciones de las antenas, tendrán solamente como dato identificativo para su elección, un valor de feromona, que indicará la probabilidad existente de que la próxima hormiga visite esa posición. No se establecerán por tanto, valores de feromonas entre los arcos que pueden unir las posiciones, tal y como puede ocurrir con el conocido problema del Viajante.

En este algoritmo, existirá una población de agentes, denominados hormigas, que irán escogiendo posiciones atendiendo a diferentes criterios. La forma de evaluar como de aptas son las hormigas, continua siendo la función fitness original que se propone en el problema RND, y que estable la relación entre porcentaje de cobertura y número de antenas utilizadas.

$$F = (\% \text{ cobertura})^2 / \text{número de antenas}$$

Con esta función, se podrán ir seleccionando aquellas hormigas que son más aptas para la resolución del problema. Asimismo, esta función fitness podrá intervenir también a la hora de crear la solución propuesta por la hormiga.

La fase de creación de la población de hormigas, es una de las etapas más importantes del algoritmo. En el caso de este algoritmo, se han definido dos posibles formas de crear la solución de las hormigas: ***en función de la cobertura*** y ***en función del número de antenas***.

- ***En Función de la Cobertura:*** Tal y como indica su nombre, este método de creación de la solución de las hormigas, busca obtener una solución que proporciona un porcentaje de cobertura mínimo. Así, al inicializarse una hormiga, irá escogiendo una a una que posiciones visitar en base a su probabilidad, o lo que es lo mismo, su valor de feromona, hasta que o bien se consiga alcanzar el porcentaje mínimo de cobertura indicado o bien, hasta que ya no haya más posiciones que visitar.
- ***En Función del Número de Antenas:*** El funcionamiento de este segundo método de creación de la solución de cada hormiga, funciona de forma similar al anterior, salvo que ahora se trabaja con el número de antenas. Al iniciarse una hormiga, escogerá una a una que posiciones visitar en base al valor de su feromona, hasta el momento que haya seleccionado el número de antenas indicado, o bien hasta que ya no haya más posiciones que visitar.

A partir de esta primera fase inicial en la creación de la solución para una hormiga, se han desarrollado dos versiones de este mismo algoritmo. En la primera versión, la solución que escoge finalmente la hormiga será simplemente siguiendo el proceso anterior, y una vez realizado esto, se puede establecer que la hormiga ha encontrado su solución. Sin embargo, se ha desarrollado una nueva versión, que escoge el subconjunto de solución con mayor fitness.

En esta versión, e independientemente del método que se trate (en función de las antenas o de la cobertura), ocurre que tras su ejecución, tal y como se ha explicado en cada uno de ellos, se irá calculando el fitness de la solución, tomando únicamente la primera posición, seguidamente la dos primeras, y así hasta tomar todas. Tras esto, se parte la solución en aquella posición que de forma conjunta con las seleccionadas

previamente proporcione un mayor fitness. De este modo, se evita hacer uso de un mayor número de antenas, que únicamente provocan que disminuya el fitness al no mejorar de forma proporcional la cobertura que ofrece.

Destacar, que para ambos métodos, no se permite nunca seleccionar más de una vez una misma posición, tal y como establece el algoritmo general de colonias de hormigas, ya que además, en el caso de este problema no modificaría en absoluto la solución, y únicamente ocasionaría que tardase más en encontrarla. Por ello, se establece una lista tabú de posiciones ya visitadas, que no puede volver a seleccionar.

Puesto que estamos hablando de un sistema de colonia de hormigas, y ya que la decisión que toma cada hormiga de seleccionar o no una determinada posición para colocar una antena depende por completo de su probabilidad de selección (cantidad de feromona), surge la necesidad de tener que actualizar los valores de esta feromona en cada posición de forma adecuada, siguiendo los criterios de las colonias de hormigas y adaptándolo a las circunstancias del problema RND.

A la hora de idear el algoritmo, se pensó en que lo mejor con vistas al resultado final de la solución era actualizar la probabilidad de cada posición que es susceptible de albergar una antena en base al solapamiento. Cuando se habla de solapamiento en el problema RND, se hace referencia a la cantidad de localizaciones que reciben cobertura de más de una antena. Este hecho es poco conveniente, ya que se pretende minimizar el número de antenas empleadas, y si existe excesivo solapamiento, es indicador de que se están empleando más antenas de las estrictamente necesarias. Por esta razón, se tomó la decisión de actualizar la feromona o probabilidad de selección de las posiciones en base a este solapamiento. Con el propósito de que esta actualización de feromona fuese lo más adecuada posible y que tuviese en cuenta toda la información que afectase a su estado real, se decidió realizar dos tipos de actualizaciones a cada posición. Estos tipos de actualizaciones se realizan de forma conjunta, es decir, que uno no sustituye al otro, sino que se realizan seguidamente, en el orden que se muestra a continuación:

- ***En base a Solapamiento Global:*** Para esta actualización, se tiene en cuenta el solapamiento global que produce el total de la solución. Para el cálculo de la nueva feromona o probabilidad de selección, se establece un nuevo parámetro. Este nuevo parámetro es una constante definida como α , que

permite obtener el nuevo valor de feromona para la posición mediante la siguiente fórmula:

$$Feromona_{(t+1)} = Feromona_{(t)} + \alpha * I / Sg$$

, donde Sg es el solapamiento global de la totalidad de la solución.

- **En base a Solapamiento Local:** En diferencia a la anterior, en este tipo de actualización, únicamente se calcula el solapamiento que provoca la antena situada en esa posición. Igualmente, para el cálculo de la actualización en base al solapamiento local del valor de la feromona de la posición se dispone de una constante β , que se convierte al igual que α en un nuevo parámetro del algoritmo. La fórmula que se sigue para la actualización por solapamiento local es la siguiente:

$$Feromona_{(t+1)} = Feromona_{(t)} + \beta * I / Sl_i$$

, donde Sl_i es el solapamiento local de la posición que se está actualizando.

Estos métodos de creación de la solución de las hormigas y actualización de la probabilidad de selección de cada una de las posiciones, son las fases decisivas del algoritmo de colonia de hormigas desarrollado. Para completar la información acerca del funcionamiento y puesto que las características de esta técnica se han establecido especialmente para resolver el problema RND, a continuación se procede a describir de forma general las particularidades propias de este método, para posteriormente describir de modo estructurado las fases de proceso de esta técnica.

- Como ya se citó previamente, existirán un número N de Agentes.
- Cada agente buscará una solución.
- A cada una de las posibles localizaciones donde se puede colocar una antena, se la denominará **nodo**.
- Inicialmente, todos los nodos son **equiprobables**.

- Una vez que todos los agentes de la población han encontrado una solución, se actualizará la probabilidad de cada nodo en función del solapamiento global para cada una de las soluciones de la que forma parte y de su solapamiento local.
- Al finalizar un ciclo, se calculará la probabilidad de selección de cada nodo, normalizando la suma de las distintas probabilidades obtenidas para ellos en todas las soluciones.
- Cuando un nodo posea probabilidad negativa, se normalizará a probabilidad 0.

Una vez descritas de forma superficial las principales particularidades de la técnica que se va a desarrollar, se procede a describir de forma algorítmica, cómo procede esta técnica.

1. Determinación de los parámetros de configuración (nº de agentes, umbral, tamaño del territorio, nº de ciclos, etc.).
2. Obtención de las coordenadas de posibles localizaciones de antenas en el territorio.(Nodos)
3. Distribución uniforme de probabilidad de selección de cada nodo.
4. Mientras $N < N^\circ$ de ciclos
 - a. Para cada agente establecido
 - i. Mientras la cobertura de la solución del agente $<$ Umbral (Caso Creación en función de Cobertura) o Mientras el número de antenas de la solución del agentes $<$ Umbral (Caso Creación en función de Antenas)
 - Selección de un nodo aleatoriamente de forma proporcional a su probabilidad.
 - Obtención de la cobertura proporcionada por el nuevo nodo, con respecto a la situación del territorio descrito por la solución del agente.

- Suma de la cobertura anterior de la solución del agente y la cobertura proporcionada por el nuevo nodo.

FIN de Mientras

ii. Si escoger sub-solución mejor fitness.

- Revisar solución para seleccionar la sub-solución con mejor fitness.

iii. Si no escoger sub-solución mejor fitness.

- Solución encontrada para la hormiga.

FIN de para cada agente

b. Al finalizar un ciclo completo

i. Cálculo de la probabilidad actualizada para cada solución de forma global mediante la siguiente fórmula:

$$P_{n_i}(t+1) = P_{n_i}(t) + \alpha \frac{1}{S_g}$$

Siendo:

- **S_g**, Solapamiento global. Es el número de localizaciones total del territorio que reciben cobertura por más de una antena. Este valor será igual para todos los nodos.
- **P_{n_i}(t)**, La probabilidad de que el nodo *i* sea elegido en el instante *t*.
- **α**: Una constante de actualización de la probabilidad.

ii. Para cada nodo seleccionado en la solución, para cada hormiga de la población:

- Cálculo de la probabilidad actualizada del nodo de forma local mediante la siguiente fórmula:

$$P_{n_i}(t+1) = P_{n_i}(t) + \beta \frac{1}{S_{l_i}}$$

Siendo:

- **Sl_i** : Solapamiento local. Número de localizaciones total del territorio que reciben cobertura por la antena que se está estudiando (i), siempre y cuando, además reciban cobertura de otra antena.
- **$Pn_i(t)$** : La probabilidad de que el nodo i sea elegido en el instante t .
- **β** : Una constante de actualización de la probabilidad.

FIN de para cada nodo de la solución

iii. Calculo de la probabilidad de selección de cada nodo:

- Si tiene una probabilidad negativa, ponerla a cero
 $\rightarrow Pn_i = 0$.

- Disipar la probabilidad de todos los nodos:

Para todo i , $Pn_i = Pn_i * \gamma$

Siendo:

- **γ** : Constante de disipación con un valor positivo menor que 1.

iv. Normalizar todas las probabilidades actualizadas de cada nodo, para obtener valores entre 0 y 1 en todos los nodos, consiguiendo que al final, las probabilidades de todos los posibles nodos sumen 1.

FIN de Mientras $N < N^\circ$ de ciclos

5. Seleccionar la mejor solución de entre las proporcionadas por los distintos agentes.

Tras la descripción algorítmica sobre el procedimiento de esta técnica, se muestra a continuación un esquema con las principales fases de dicho algoritmo, simplificando así la comprensión del mismo.

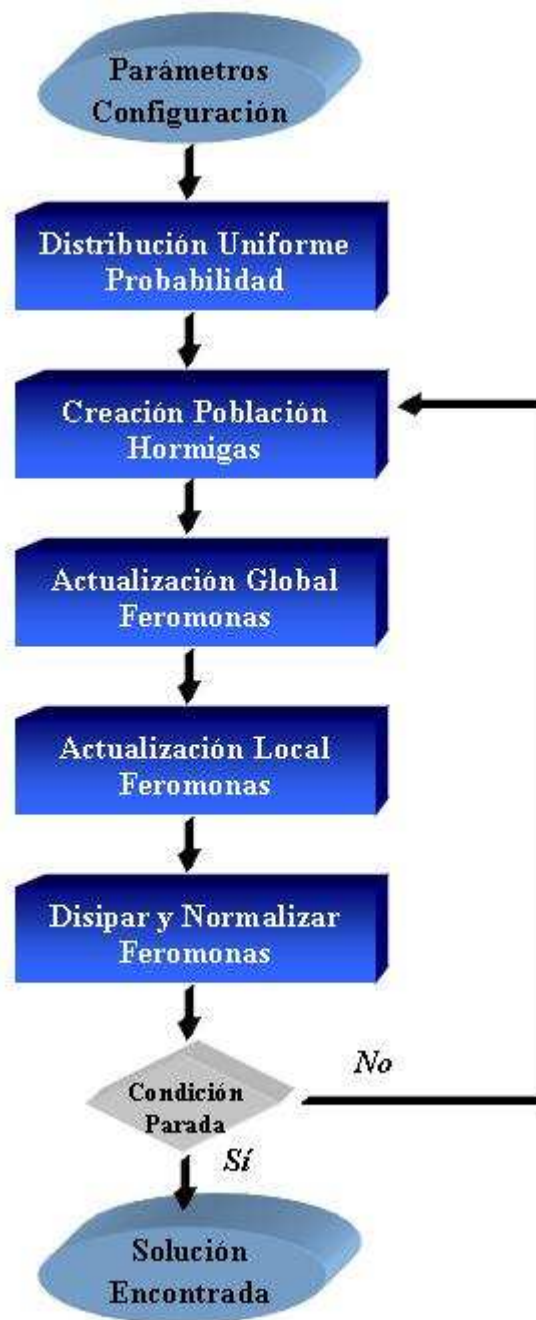


Ilustración 27: Esquema de las Fases del Algoritmo de Colonias de Hormigas.

4.5 Teoría de Clustering

El proceso de Clustering consiste en la división de los datos en grupos de objetos similares. Para medir la similitud entre los objetos, se suele utilizar diversas formas de distancia, como pueden ser la distancia euclídea, de Manhattan, etc. Clustering, no es más que una técnica de aprendizaje automático no supervisado. Desde un punto de vista más práctico, el clustering juega un papel muy importante en aplicaciones de minería de datos, tales como la exploración de datos científicos, recuperación de información, marketing, aplicaciones web, etc.

Para poder comprender de forma totalmente completa esta ampliación del algoritmo de colonias de hormigas con clustering, se procede a describir a continuación los dos algoritmos de clustering empleados para la obtención de clusters o agrupaciones de las posiciones de antenas con las que trabaja posteriormente el algoritmo de colonias de hormigas:

- **Simple K-Medias:** Se trata de un algoritmo clasificado como Método de Particionado y Recolocación, muy popular por su empleo en numerosas aplicaciones científicas e industriales. El nombre le viene porque representa cada uno de los clusters por la media (o media ponderada) de sus puntos, es decir, por su centroide. Este método únicamente se puede aplicar a atributos numéricos, y los outliers (valores desacordes con el resto) le pueden afectar muy negativamente.

Sin embargo, la representación mediante centroides tiene la ventaja de que tiene un significado gráfico y estadístico inmediato, en donde la suma de las discrepancias entre un punto y su centroide, expresado a través de la distancia apropiada, se usa como función objetivo. La función objetivo, suma de los cuadrados de los errores entre los puntos y sus centroides respectivos, es igual a la varianza total dentro del propio cluster. La suma de los cuadrados de los errores se puede racionalizar, como el negativo del log-likelihood, para modelos mixtos que utilicen distribuciones normales. Por lo tanto, el método de las k-medias se puede derivar a partir del marco probabilístico.

Existen dos versiones del método de las k-medias. La primera es parecida al algoritmo Expectación-Maximización (EM), y se basa en dos pasos iterativos: primero reasigna todos los puntos a sus centroides más cercanos, y en segundo lugar

recalcula los centroides de los nuevos grupos creados en el anterior. El proceso continúa hasta alcanzar un criterio de parada (por ejemplo que no se realizan nuevas reasignaciones). Esta versión se conoce como algoritmo de Forgy. La segunda versión reasigna los puntos basándose en un análisis más detallado de los efectos causados sobre la función objetivo al mover un punto de su cluster a otro nuevo. Si el traslado es positivo, se realiza, en caso contrario se queda como está.

Por tanto, resumiendo, se trata de una técnica de clustering en la que dado un conjunto de datos R y un número k de agrupaciones (cuantos cluster se desean crear), se encarga de determinar un número k de centros, que representarán los distintos clusters. A partir de estos k centros, se calcula para el resto de los datos el cuadrado de la distancia media respecto a estos centros, y se asignará el dato a aquel cluster con el que presente menor distancia con respecto a su centro.

- **EM:** Se trata de un método de clustering probabilístico, que pretende obtener la FDP (*Función de Densidad de Probabilidad*) desconocida a la que pertenecen el conjunto completo de datos. Esta FDP se puede aproximar mediante una combinación lineal de N componentes, definidas a falta de una serie de parámetros, que son los que hay que averiguar :

$$P(x) = \sum_{j=1}^{NC} \pi_j p(x; \theta_j), \quad \sum_{j=1}^{NC} \pi_j = 1.$$

, donde π_j son las probabilidades a priori de cada cluster cuya suma debe ser 1, que también forman parte de la solución buscada, $P(x)$ indica la FDP arbitraria y $p(x; \theta_j)$ la función de densidad del componente j . De este modo, se asigna a cada cluster las respectivas muestras de datos que pertenecen a cada una de las densidades que se mezclan.

En cuanto a las FDP, se pueden estimar de forma arbitraria utilizándose para ello, FDP normales n -dimensionales, t-Student, Poisson, log-normales y Bernoulli. El ajuste de los parámetros del modelo, requiere alguna medida de bondad, o lo que es lo mismo, cómo de bien encajan los datos de la distribución que los representa. Se trataría entonces de estimar los parámetros buscados θ , maximizando este valor de bondad o *likelihood*. Normalmente, lo que se calcula es el logaritmo de este *likelihood*, ya que es más fácil de calcular.

El algoritmo EM procede en dos pasos que se repiten de forma iterativa:

- **Expectación:** Utiliza los valores de los parámetros iniciales o proporcionados por el paso Maximization de la iteración anterior, obteniendo diferentes formas de la FDP buscada.
- **Maximización:** Obtiene nuevos valores de los parámetros a partir de los datos proporcionados por el paso anterior.

Después de una serie de iteraciones, el algoritmo EM tiende a un máximo local de la función L. Finalmente se obtendrá un conjunto de clusters que agrupan el conjunto de proyectos original. Cada uno de estos cluster estará definido por los parámetros de una distribución normal.

4.6 Descripción Algoritmo de Colonias de Hormigas con Clustering Desarrollado.

La tercera y última propuesta estudiada en este proyecto para resolver el problema de diseño de redes de comunicación RND, no es más que una nueva versión del algoritmo de colonia de hormigas explicado previamente, a la que se le ha incluido clustering.

En el problema RND, se proporcionan una serie de posibles localizaciones para las antenas que se encuentran distribuidas por diferentes áreas del terreno. Sin embargo, cuando es el caso de un problema en el que existe una gran cantidad de estas posibles localizaciones, como es el que aquí se estudia, es muy posible, que para cada una de las distintas áreas del terreno existan varias posibles localizaciones que puedan proporcionarle cobertura.

Analizando el comportamiento del algoritmo de colonia de hormigas, se llega a la conclusión de que el espacio de búsqueda con el que se está trabajando es demasiado grande, y se incluye además otra complicación, que es que las antenas vecinas en la codificación del individuo no tienen por qué encontrarse próximas espacialmente, lo que provoca que sea complicado obtener la solución óptima. Ante esta situación, y el hecho de que se pretende minimizar el número de antenas empleadas, minimizando a la vez el solapamiento de cobertura entre distintas antenas, se decidió aplicar antes de ejecutar el algoritmo de colonias, una técnica de clustering, para conseguir obtener agrupaciones de los emplazamientos de antenas por su proximidad espacial, de forma que se consiguiera relajar el problema, disminuyendo el espacio de búsqueda y consiguiendo conocer que posiciones son vecinas de otras.

Con esto, lo que se consigue es conocer a priori que antenas están cerca de otras, y de este modo, se puede establecer que de cada grupo únicamente se podrá seleccionar una posición para situar una antena, ya que en principio, debería poder abarcar toda el área, si se selecciona la posición óptima del grupo.

Se propone por tanto, el uso de Minería de Datos, en concreto de técnicas de Clustering, con el fin de obtener las agrupaciones deseadas. Para el desarrollo de esta última técnica, ha sido necesario aplicar de forma previa a la ejecución del algoritmo, la

técnica de clustering, con el propósito de obtener un fichero con la agrupación de las posiciones que presentar al algoritmo de colonias de hormigas.

Para obtener los ficheros de cluster, se ha hecho uso de la herramienta de minería de datos Weka, mediante la cual se han aplicado dos algoritmos de clustering, Simple K-Medias y EM, explicados anteriormente.

En realidad son algoritmos muy similares, pero se decidió aplicar y estudiar los resultados con ambos para no dejar ninguna posible área de estudio sin investigar. Del mismo modo, se optó por obtener para cada uno de los algoritmos los resultados estableciendo 40, 50, 60 y 70 clusters.

En la imagen que se muestra a continuación, se puede ver un ejemplo de las agrupaciones que se forman para una distribución real con 70 cluster para el problema del escenario de Málaga que se está estudiando.

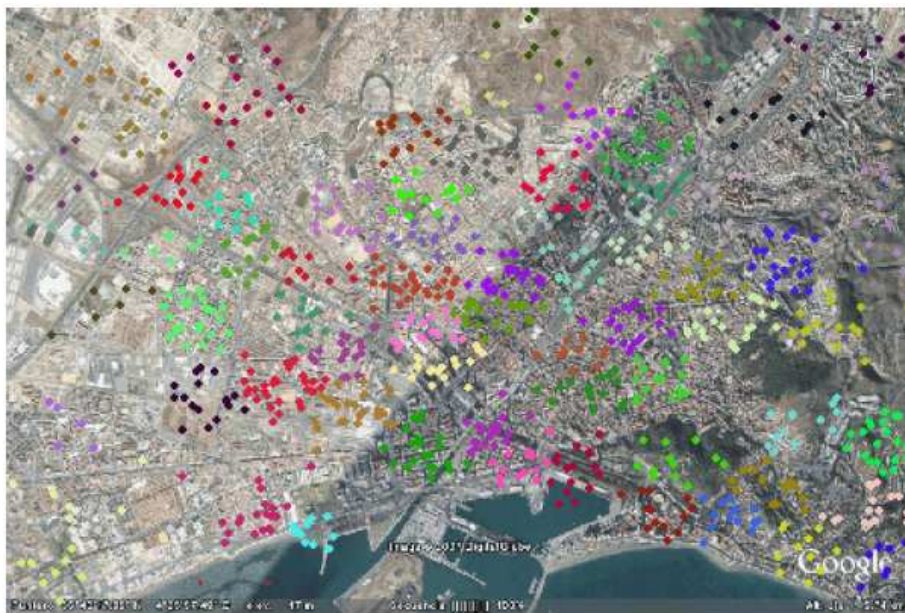


Ilustración 28: Distribución con 70 Cluster del algoritmo Simple K-Medias en el escenario de Málaga.

Al aplicar la técnica de clustering y establecer que únicamente se podrá seleccionar una posición de cada cluster como máximo, se consigue establecer ya desde un principio el número máximo de antenas que se podrá emplear, y el algoritmo será capaz de este modo, de minimizar más fácil y rápidamente el número de ellas necesario para constituir la solución.

Una vez que ya se dispone de los ficheros con la información de clustering generada por la herramienta de minería de datos, se puede aplicar el algoritmo de colonias de hormigas. Sin embargo, este algoritmo, no funciona exactamente igual que el algoritmo simple descrito anteriormente, sino que ha sido necesario someterlo a una serie de modificaciones para adaptarlo al nuevo comportamiento deseado en función de las agrupaciones de antenas obtenidas.

El funcionamiento general del algoritmo, continúa siendo el mismo, se ejecuta iterativamente el ciclo de crear la población de hormigas con sus soluciones, y se actualizar las probabilidades de selección de cada posición para las antenas en base al solapamiento global y local. No obstante, ahora cambia la forma en que la hormiga crea la solución, y la forma en la que se actualizan las probabilidades de las posiciones de antena.

Ya no existen dos métodos de creación de solución, simplemente se establece una versión de la anterior creación en función de la cobertura. Se establece un porcentaje de cobertura que se pretende alcanzar si es posible. En este momento, la hormiga comenzará a seleccionar de forma aleatoria pero en función del valor de feromona, una a una las posiciones. Sin embargo, en este caso, se establece la restricción de que únicamente podrá seleccionar una posición de cada cluster. Para ello, la hormiga elegirá aleatoriamente un cluster, y a continuación una de las posiciones perteneciente a dicho cluster de forma probabilística en función de la probabilidad de selección. Puesto que no se puede seleccionar más de una posición por cada cluster, la hormiga conocerá los cluster que ya ha utilizado mediante la comprobación de una lista tabú en la que se irán incluyendo aquellos cluster de los que ya se ha tomado una antena. La hormiga tomará tantas posiciones como sea necesario para alcanzar la cobertura indicada, o bien continuará escogiendo posiciones hasta que haya seleccionado antenas de todos los cluster, a pesar de que no se consiga la cobertura indicada.

A partir de aquí, y al igual que ocurría en el caso del algoritmo de colonias de hormigas simple, se seleccionará la sub-solución de la hormiga con mayor valor de fitness.

En este caso, no se ha desarrollado el método de empleo del número de antenas como umbral, ya que en cierto modo va incluido, al establecer que solamente se puede seleccionar una antena de cada cluster, y por tanto, indicar que como máximo se tendrán N antenas, siendo N el número de cluster con el que se trabaja.

En lo que se refiere a la actualización del valor de feromona de cada una de las posiciones de antenas, la diferencia con respecto al algoritmo de Colonias de Hormigas sin Cluster, se encuentra en que en este caso, la equiprobabilidad inicial de las antenas no se realizará entre el total de estas, si no entre el total de antenas de cada cluster. Asimismo, los clusters también recibirán un valor de probabilidad de selección, que inicialmente será equiprobable.

Resumiendo, el proceso consistirá en establecer en primer lugar, una probabilidad de selección a cada cluster, que inicialmente será equiprobable, para después y para cada uno de ellos, establecer las probabilidades de las antenas, de forma individual para cada cluster (la suma de las probabilidades de las antenas será del 100% para cada uno de ellos).

Estas son las diferencias entre ambos algoritmos, y con esto concluye la descripción de los algoritmos empleados en el estudio.

Capítulo 5

Resultados y Análisis

En el presente apartado del documento, se presenta el análisis del conjunto de pruebas realizadas para el estudio de los algoritmos desarrollados, con el fin de poder discernir la adecuación de los mismos a la resolución del problema RND, las mejores configuraciones de los parámetros para cada algoritmo y la aproximación al óptimo de los mejores resultados generados por los algoritmos bioinspirados elaborados en el proyecto.

5.1 Resultados y Análisis del Algoritmo Genético

A la hora de analizar el algoritmo genético desarrollado para su adecuación a la resolución del problema RND, se ha realizado un conjunto de pruebas completo y suficiente, que comienzan por la determinación de una serie de parámetros iniciales, que ayuden a determinar la mejor configuración del algoritmo.

Antes de comenzar con el análisis de los parámetros de configuración que definiesen el mejor algoritmo genético posible, se decidió estudiar de forma los resultados que se obtendrían guiando el algoritmo con las dos funciones de fitness diseñadas (Original y Por Cobertura), ya descritas en el “4.2 Descripción Algoritmos Genéticos Desarrollados” del presente documento. Por esta razón, se ejecutaron un conjunto de pruebas con diversas configuraciones, que se pueden encontrar en la Tabla 3, para poder establecer la función de fitness más conveniente para trabajar, a la hora de buscar la solución óptima al problema RND.

Tamaño Población	Periodo Estancamiento	Tipo Fitness	Tipo Creación Población Inicial	Tipo Selección	Tipo Cruce	Max. Mutación	Min. Mutación	Cobertura (%)	Antenas	Fitness
500	100	Original	Limitada [50]	Campeonato	Uniforme	0.4	0.15	82,58	45	151,57
500	100	Por Cobertura	Limitada [50]	Campeonato	Uniforme	0.4	0.15	89,99	73	110,95
500	100	Original	Limitada [50]	Torneo [4]	Uniforme	0.4	0.15	81,73	45	148,47
500	200	Por Cobertura	Limitada [50]	Torneo [4]	Uniforme	0.2	0.05	87,93	63	122,74
500	100	Original	Limitada [55]	Torneo [8]	Uniforme	0.4	0.15	81,86	47	142,609
500	100	Por Cobertura	Limitada [50]	Torneo [8]	Uniforme	0.4	0.15	91,13	95	87,42

Tabla 3: Resultados de las pruebas realizadas para el análisis de la mejor función de fitness a aplicar.

Tal y como se puede observar en la tabla, se muestra la posibilidad de obtener una mejor solución al problema RND mediante la aplicación de la función Original de fitness. Se aprecia como con la función de fitness original se consigue obtener un porcentaje de cobertura bastante alto, utilizando para ello un número mínimo de antenas, mientras que en el caso de la función de fitness “Por Cobertura”, se logra un porcentaje de cobertura más alto, pero al precio de utilizar un número mucho mayor de antenas, lo que produce que el valor de fitness sea peor y no compense obtener una mayor cobertura si es necesario establecer en ocasiones, casi el doble de antenas.

Tras realizar este análisis inicial sobre la mejor función de fitness a emplear para el algoritmo, se ha buscado determinar cuál será el mejor método de creación de la población inicial para el algoritmo, para poder decantarse por uno de los dos métodos desarrollados, comentados previamente en el apartado “4.2 Descripción Algoritmos Genéticos Desarrollados”. Para esto, ha sido necesario de manera inicial, ejecutar un pequeño conjunto de pruebas, que permitiesen determinar para el método de creación de población inicial mediante limitación de uso de antenas, el número de antenas a establecer para dicha limitación. Esto se realiza así, ya que el número de antenas que se empleen en los individuos de la población inicial, constituyen un factor que puede afectar a la correcta resolución del problema. Para ello, se decidió ejecutar una batería de pruebas con parámetros básicos, para los que únicamente se modificaba el número de antenas máximo para la creación de los individuos de la población inicial, estableciendo

dichos valores entre 10 y 90. La elección de valores comprendidos en este intervalo, se debe principalmente a la necesidad de contar con un número de antenas iniciales suficientemente pequeño como para conseguir un menor coste computacional del algoritmo y disminuir las posibilidades de elección para evitar que el algoritmo tenga que disminuir en gran cantidad el número de antenas de la solución, pero lo suficientemente grande, para ofrecer la posibilidad al algoritmo de explorar las distintas alternativas de solución. Ante esto, se han realizado las siguientes pruebas:

Prueba	Nº Antenas Inicialización	Nº Antenas Utilizadas Solución Final
1	10	46
2	20	46
3	30	47
4	40	48
5	50	49
6	60	45
7	70	45
8	80	47
9	90	49

Tabla 4: Pruebas Nº Antenas Inicialización AG

Se puede observar, tanto en la Tabla 4 como en el Gráfico 1, que con independencia del número inicial de antenas que se establezcan para la limitación, estas no superan en ninguno de los casos estudiados el uso de las 50 antenas para la solución final.




Gráfico 1: Gráfico Nº Antenas Solución Final en base a Nº Antenas Inicialización.

Con esto se puede concluir que cualquier inicialización es adecuada para obtener un buen valor de fitness, ya que todas consiguen reducir el número de antenas necesarias a un valor cercano a 46 antenas. Sin embargo, la diferencia entre ellas es la velocidad, ya que el tiempo de evaluación de los individuos depende en un alto grado del número de antenas activas que tenga. Por esta razón, se decidió establecer que para los casos en los que se aplicase el método de creación de población inicial mediante la limitación del número de antenas, se utilizará el valor de 50 como parámetro, ya que tal y como se ha comentado con anterioridad, se ha observado que en las pruebas realizadas la solución final no emplea en ningún caso más de este número de antenas y se conseguirá mejorar la velocidad de ejecución del algoritmo. Con esto, se conseguirá que desde un inicio, el algoritmo se centre en encontrar un número de, aproximadamente 50 localizaciones de antenas, potenciando de este modo la búsqueda desde el inicio de la solución óptima.

Una vez encontrado el valor óptimo a establecer como parámetro para el método de creación limitado de población inicial del algoritmo, se procede a determinar mediante una nueva batería de pruebas, los parámetros más adecuados para obtener la mejor solución posible del problema Radio Network Design (RND). En primer lugar se pretende identificar qué método de creación de población inicial es más adecuado. Para esto, se ejecutan unas pruebas que permiten observar que empleando el método limitado se consigue un valor de la función de adaptación mayor, y además que se consigue de forma más rápida con un menor número de generaciones. Estos resultados se pueden observar en la Tabla 5.

Tamaño Población	Periodo Estancamiento	Tipo Fitness	Tipo Creación Población Inicial	Tipo Selección	Tipo Cruce	Max. Mutación	Min. Mutación	Cobertura	Antenas	Fitness
500	100	Original	Original	Torneo[8]	Uniforme	0.2	0.05	83,30%	47	147,65
500	100	Original	Original	Campeonato	Uniforme	0.2	0.05	86,46%	51	146,57
500	100	Original	Limitada [50]	Torneo[8]	Uniforme	0.2	0.05	84,53%	48	148,89
500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	83,55%	47	148,55

Tabla 5: Resultados Pruebas para Tipo de Creación Población Inicial.

En este proceso para la búsqueda de la mejor configuración del algoritmo, el siguiente paso que se produjo fue la determinación del tipo de selección de individuos que se iba a emplear. En el caso del algoritmo con el que se está tratando, y tal y como ya se describió en el “4.2 Descripción Algoritmos Genéticos Desarrollados”, se cuentan con dos posibles métodos de selección: Torneo y Campeonato. Para poder

estudiar la adecuación de estos métodos para la resolución del problema RND en el algoritmo genético que está siendo caso de estudio, se establecieron pruebas para obtener los resultados con: Torneo de 4, 8, 16 y 24 individuos y Campeonato.

Tamaño Población	Periodo Estancamiento	Tipo Fitness	Tipo Creación Población Inicial	Tipo Selección	Tipo Cruce	Max. Mutación	Min. Mutación	Cobertura	Antenas	Fitness
500	100	Original	Limitada [50]	Torneo[4]	Uniforme	0.2	0.05	81,81%	45	148,74
500	100	Original	Limitada [50]	Torneo[8]	Uniforme	0.2	0.05	85,89%	49	150,34
500	100	Original	Limitada [50]	Torneo[16]	Uniforme	0.2	0.05	85,08%	50	144,8
500	100	Original	Limitada [50]	Torneo[24]	Uniforme	0.2	0.05	82,12%	46	146,63
500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	84,18%	47	150,77

Tabla 6: Resultados Pruebas para Operador de Selección.

Tras las pruebas, que pueden encontrarse en la Tabla 6, se determinó que los mejores resultados se obtenían con Campeonato y Torneo para 8 individuos, que ofrecen un valor de fitness muy similar. Sin embargo, al utilizar el Torneo con 8 individuos se podía apreciar como el algoritmo llegaba rápidamente a la solución, pero aún así, se vio que en el caso de Campeonato, las opciones que se estudiaban eran mucho mayores, y se conseguía una mejor solución, ya que exploraba más posibles combinaciones de antenas, y conseguía obtener un menor número de ellas, para aproximadamente el mismo valor de cobertura. Ante esto, se decidió que la mejor opción sería la de emplear el método de selección de Campeonato, para establecerlo en la mejor configuración del algoritmo AG.

Al igual que se ha estudiado el mejor método de selección para el algoritmo, se analizó el mejor método de cruce de los individuos, para la generación de la nueva población. En este caso, se habían desarrollado dos métodos: Simple y Uniforme. Los resultados obtenidos de las pruebas, fueron mucho más obvios que en casos anteriores. No cabía duda, como se observa en la Tabla 7, que el método de cruce Uniforme ofrece unos valores de fitness mucho mayores que el método de Cruce Simple, y por tanto será el método elegido para utilizarlo en la configuración óptima del algoritmo.

Tamaño Población	Periodo Estancamiento	Tipo Fitness	Tipo Creación Población Inicial	Tipo Selección	Tipo Cruce	Max. Mutación	Min. Mutación	Cobertura	Antenas	Fitness
500	100	Original	Limitada [50]	Campeonato	Simple	0.2	0.05	66,32%	50	87,98
500	100	Original	Limitada [50]	Campeonato	Simple	0.2	0.05	65,27%	50	85,21
500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	82,69%	45	151,94
500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	83,99%	47	148,55

Tabla 7: Resultados Pruebas para Operador de Cruce.

Tamaño Población	Periodo Estancamiento	Tipo Fitness	Tipo Creación Población Inicial	Tipo Selección	Tipo Cruce	Max. Mutación	Min. Mutación	Cobertura	Antenas	Fitness
500	100	Original	Limitada [50]	Campeonato	Uniforme	0.5	0.3	86,05%	55	134,63
500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.005	82,42%	45	150,97
500	100	Original	Limitada [50]	Campeonato	Uniforme	0.1	0.0005	82,63%	46	148,46
500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	86,33%	46	151,08
500	100	Original	Limitada [50]	Campeonato	Uniforme	0.4	0.15	83,92%	48	146,33
500	100	Original	Limitada [50]	Campeonato	Uniforme	0.4	0.2	80,71%	44	148,076

Tabla 8: Resultados Pruebas para Valores Máximo y Mínimo de Mutación.

Por último, se establecieron una serie de pruebas para determinar el valor máximo y mínimo para obtener el porcentaje de mutación a ejecutar en cada generación del algoritmo AG. Tras la ejecución de un pequeño conjunto de pruebas, que puede encontrarse en la Tabla 8, se determinó que los mejores valores a utilizar serían un 0,2 como máximo y un 0,05 como mínimo, obteniendo así un rango de valor de mutación lo suficientemente grande para que se introduzca diversidad, pero lo suficientemente pequeño para no producir demasiados cambios significantes que haga que el algoritmo explore distintas soluciones en exceso, sin llegar nunca a la explotación de las mejores soluciones.

Tras esto, se determinó que el tamaño de la población sería de 500 individuos, por pruebas realizadas en la fase previa del algoritmo genético en el escenario simplificado, así como un periodo de estancamiento de 100, que establece que si tras 100 generaciones no se ha conseguido una solución mejor, se detendrá la ejecución del algoritmo.

Con esto, se define que la mejor configuración para el algoritmo genético empleando la función de fitness Original será la siguiente:

- **Tamaño Población:** 500
- **Periodo Estancamiento:** 100
- **Operador Creación Población Inicial:** Limitada[50].
- **Operador de Selección:** Campeonato.
- **Operador de Cruce:** Uniforme.
- **Valor Máximo-Mínimo Mutación:** 0.2 -0.05.

En base a esta configuración establecida, se realizaron un conjunto de pruebas para obtener los resultados que produce el algoritmo genético con esta configuración. Para ello, se realizaron un total de 25 ejecuciones del algoritmo, con el fin de obtener la media de los valores de resultados producidos y hallar un valor medio real de lo bien que funciona el algoritmo con esta configuración, considerada la óptima.

Los resultados de estas pruebas pueden encontrarse en la Tabla 9. En esta podemos encontrar que el mayor valor de fitness alcanzado tiene un valor de **155.91**, obtenido como resultado de la aplicación de la fórmula de la función de adaptación para un **83.96% de cobertura** utilizando un total de **45 antenas**.

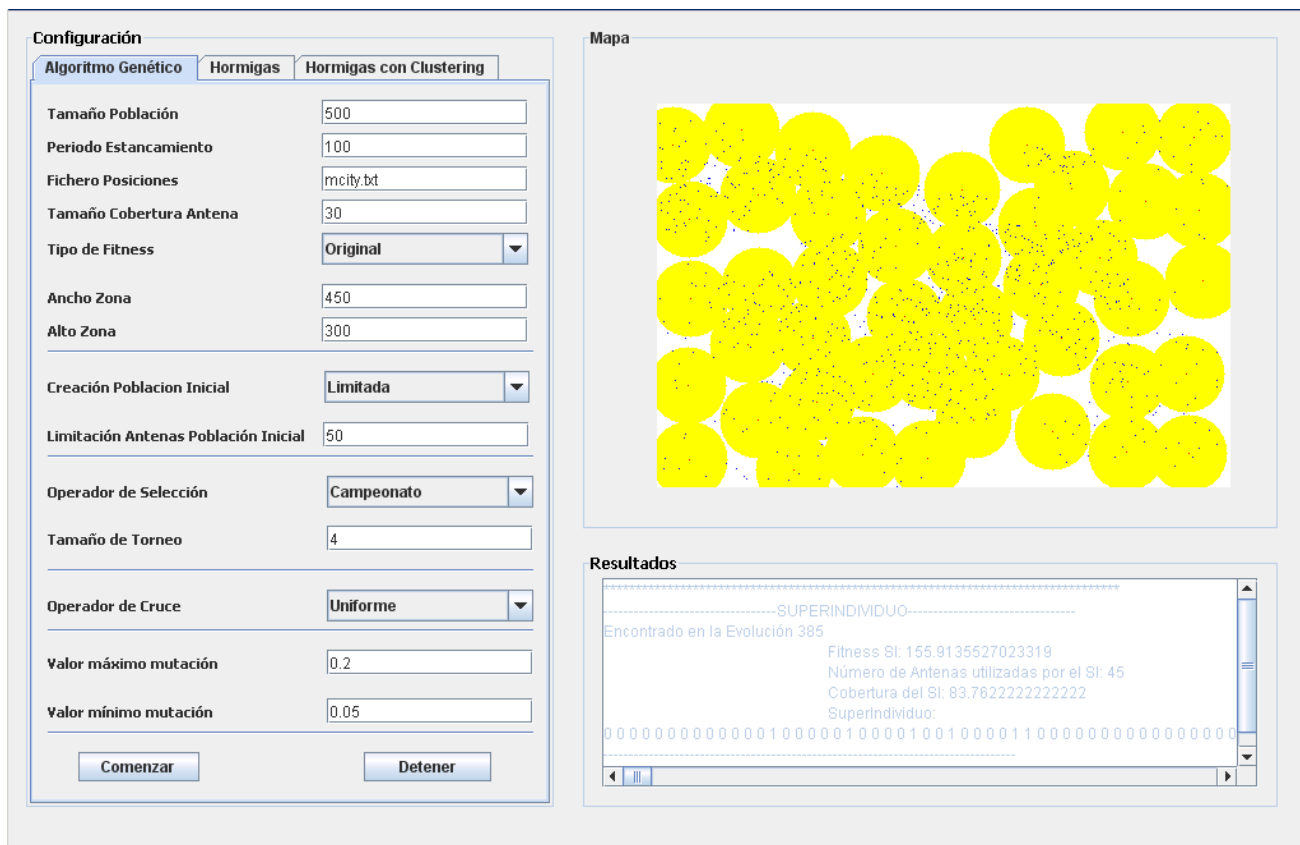


Ilustración 29: Mejor Resultado del AG.

Los AG únicamente se interesan por conseguir maximizar el fitness, sin necesidad de disponer de una visión global previa de lo que podría ser la solución, y esto produce como resultado, tal y como se puede observar en la Ilustración 31, que la distribución de las antenas obtenida no es regular, y por tanto difiera de la visión estructurada que nosotros mismos seguiríamos. Esto constituye un punto positivo para los AG, ya que conseguimos obtener una forma de enfocar el problema diferente y extraer de este modo soluciones adecuadas que por otros medios no podríamos imaginar.

En los Gráficos 2,3 y 4, se observa de forma rápida y visual los resultados de N° de Antenas, Porcentaje de Cobertura y Valor de Fitness respectivamente, para las 25 ejecuciones realizadas con la configuración obtenida como óptima para el algoritmo genético. Con estos gráficos podemos observar cómo para el caso del fitness se obtienen siempre valores comprendidos en el rango [149,156], para el caso del número de antenas empleadas entre [43,49]; y por último, en el caso del porcentaje de la cobertura, los valores se encuentran dentro del rango de valores [80,87].

Prueba	Tamaño Población	Periodo Estancamiento	Tipo Fitness	Tipo Creación Población Inicial	Tipo Selección	Tipo Cruce	Max. Mutación	Min. Mutación	Cobertura	Antenas	Fitness
1	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	83,24%	46	150,63
2	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	84,52%	47	152,026
3	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	86,46%	49	152,56
4	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	81,43%	44	150,707
5	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	83,76%	45	155,91
6	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	82,54%	45	151,41
7	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	84,59%	47	152,25
8	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	82,66%	45	151,85
9	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	83,84%	47	149,57
10	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	85,72%	48	153,086
11	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	84,39%	47	151,56
12	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	80,72%	43	151,55
13	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	83,55%	46	151,76
14	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	85,06%	48	150,74
15	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	81,95%	44	152,64
16	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	84,9%	47	153,39
17	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	84,73%	48	149,58
18	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	83,5%	46	151,58
19	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	82,22%	45	150,25
20	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	85,53%	48	152,42
21	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	84,96%	47	153,608
22	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	85,45%	47	155,37
23	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	82,37%	45	150,78
24	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	83,35%	45	154,4
25	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	84,54%	47	152,096

Tabla 9: Resultados AG con la Configuración Óptima.




Gráfico 2: Nº de Antenas Resultados AG con la Configuración Óptima.




Gráfico 3: Porcentaje de Cobertura Resultados AG con la Configuración Óptima.




Gráfico 4: Fitness Resultados AG con la Configuración Óptima.

Ante esta circunstancia de resultados muy semejantes para las distintas ejecuciones realizadas, y observando el Gráfico 5 de dispersión de los resultados, podemos apreciar cómo se consigue para esta configuración del algoritmo genético unos valores medios aproximados de **46 antenas, 83% de cobertura y un 152 de fitness**.

Se advierte que en ninguno de los casos de las pruebas ejecutadas, el número de antenas supera el valor de 50. Esto supone un indicador muy relevante, ya que las antenas empleadas representan un factor muy influyente para el fitness final. De este modo, se debe buscar siempre mantener la misma cobertura, pero disminuyendo el número de antenas empleadas para ello, labor muy complicada en casos como el que se trata, por el pequeño número de antenas con el que se trabaja.

Podría pensarse que la eliminación de una antena se puede conseguir fácilmente mediante el operador de mutación, pero sin embargo, si lo que se pretende es mantener el valor de cobertura, no estaríamos tratando simplemente con eliminar, sino con una sustitución óptima de otra antena de la solución que sea capaz de cubrir el espacio que ha dejado sin cobertura la eliminación de la anterior.




Gráfico 5: Resultados AG con la Configuración Óptima.

Las soluciones producidas por el AG suelen presentar la siguiente regla, y es que a mayor porcentaje de cobertura, se emplea también un mayor número de antenas, lo que hace que no se obtenga un mayor fitness.

Con los resultados mostrados en su representación en el Gráfico 6, se puede observar la evolución de las soluciones que va produciendo la ejecución del algoritmo genético. Con esta información, se puede advertir, como inicialmente se desarrolla una fase de exploración donde se producen soluciones de resultados más diversos, en las que se emplean distinto número de antenas para obtener la solución, y donde los cambios de la mejor solución se producen en un número de generaciones menor. A medida que aumenta el número de generaciones, se observa cómo se produce el inicio de la fase de explotación. En esta segunda fase, el algoritmo se centra ya en obtener el mayor porcentaje de cobertura posible, utilizando para ello aproximadamente el mismo número de antenas, por lo que se observa que las mejoras son menos significativas y se encuentran en un mayor número de generaciones, ya que en esta fase donde se dispone ya de una solución lo suficientemente buena, es el operador de mutación el que juega un papel más importante para introducir diversidad y encontrar soluciones no exploradas.




Gráfico 6: Evolución Fitness/Cobertura/Nº Antenas para la mejor solución del AG.

Todo lo comentado de la evolución que se produce con el algoritmo genético, se puede observar a simple vista en el Gráfico 6, donde se observa como el valor de la función de adaptación crece notablemente durante las primeras generaciones del algoritmo, para posteriormente llegar a un punto estable donde la mejora de este valor se alcanza paulatinamente, de forma menos significativa. Lo mismo ocurre en el caso del porcentaje de cobertura, que crece en mayor grado a lo largo de las primeras generaciones, para después mejorar en detalles menos observables; y el caso del número de antenas, que al contrario de los otros dos atributos a valorar de la solución, disminuye, para conseguir la aplicación de un menor número de antenas, intentando mantener el mismo o mayor porcentaje de cobertura.

5.2 Resultados y Análisis del Algoritmo de Colonias de Hormigas Escogiendo Mejor Fitness de la Solución.

Una vez estudiado el comportamiento del Algoritmo Genético en la resolución del problema RND, se procede a estudiar la adecuación del Algoritmo de Colonia de Hormigas para resolver este mismo problema.

Tal y como se ha explicado con anterioridad en el apartado “4.4 Descripción Algoritmo de Colonias de Hormigas Desarrollado”, se han diseñado dos versiones del mismo algoritmo de Colonias de Hormigas, uno en el que la solución seleccionada en cada ejecución es el resultado hasta conseguir alcanzar un umbral, y una segunda versión en la que la solución seleccionada finalmente será el subconjunto que proporcione mejor valor de fitness, a partir de la solución obtenida para alcanzar el umbral mínimo preestablecido. En este apartado, se estudiarán las soluciones obtenidas de la segunda versión del algoritmo.

El estudio de este algoritmo se realizará mediante dos análisis diferentes: 1) Para la cobertura como umbral y 2) Para el número de antenas como umbral. Esto se debe al hecho de que el algoritmo ha sido desarrollado y preparado para poder ejecutarse estableciendo un porcentaje de cobertura mínimo a alcanzar por la hormiga y de este modo obtener el mínimo número de antenas para esa cobertura, o bien, estableciendo el número mínimo de antenas, y observar de este modo el porcentaje de cobertura máximo que se podría obtener estableciendo ese número concreto de hormigas.

Sin embargo, en primer lugar se va a analizar de forma conjunta el nº de evaluaciones máximas para el algoritmos, así como los valores de α , β y γ ; o lo que es lo mismo, los valores de las constantes de actualización de la feromona para la selección de cada una de las posibles localizaciones de antenas.

En primer lugar, se procede al estudio del número de evaluaciones necesarias para obtener un adecuado valor de fitness para la solución final. El valor de este parámetro resulta de gran importancia para la ejecución del algoritmo, ya que en buena medida es capaz de limitar la capacidad de encontrar una solución óptima. Por tanto, será necesario establecer un valor para este parámetro lo suficientemente grande para permitir la exploración y evolución de las soluciones, pero a su vez justo, para evitar que la ejecución del algoritmo se alargue de forma innecesaria.

Para estudiar qué valor es el más adecuado para este parámetro se ejecutaron pruebas con valores de un máximo de evaluaciones de 100000, 200000, 500000. Puesto que aún no se había procedido a estudiar el resto de parámetros se utilizó el mecanismo del algoritmo de colonias de hormigas con 40 antenas como umbral, para el cual se fijaron los valores de 0.003, 0.002 y 0.002 para γ , α y β respectivamente. Además, desde un inicio se estableció que el tamaño de población sería de 500 individuos basándose en las pruebas realizadas con el Algoritmo Genético.

Individuos Evaluados	Tamaño Población	Tipo	Umbral	GAMMA	ALFA	BETA	Evaluación Mejor	Fitness	Cobertura	Antenas
100000	500	Antenas	40	0.003	0.002	0.002	3698	95,94	61,95%	40
200000	500	Antenas	40	0.003	0.002	0.002	694	96,29	62,062%	40
500000	500	Antenas	40	0.003	0.002	0.002	2528	97,61	62,48%	40

Tabla 10: Resultados pruebas para el estudio de número de evaluaciones máximas para el algoritmo de Colonias de Hormigas Modificado.

Los resultados obtenidos para estas tres pruebas se pueden apreciar en la Tabla 10. En estos valores, podemos observar a simple vista como el valor del fitness aumenta a medida que a su vez se incrementa el número de evaluaciones a ejecutar de 100000 a 500000, a pesar de no ser cambios demasiado significativos, y es por esta razón que se decidió realizar todo el conjunto de pruebas iniciales con 500000 evaluaciones.

Tras el estudio de los resultados, se pensó que podrían obtenerse mejores resultados con un mayor número de evaluaciones, pero sin embargo estas mejoras no serían tan significativas como para ejecutar todo el conjunto de pruebas iniciales del estudio con un mayor número de evaluaciones, que lo único que provocarían sería retrasar la obtención de los resultados y no poder determinar con mayor rapidez cual es la mejor configuración para el resto de los parámetros.

Ante esto, se tomó la decisión de que el juego de pruebas inicial para determinar la configuración óptima del algoritmo, se realizaría con 500000 evaluaciones, y una vez determinada la mejor configuración del algoritmo, ejecutar pruebas con 1000000 de evaluaciones y observar si se obtienen pequeños aumentos en el valor del fitness.

Una vez decidido el número de evaluaciones necesarias para obtener una solución aceptable mediante la ejecución de este algoritmo, se procede al estudio de los valores más adecuados para los parámetros γ , α y β .

Para este caso, se ejecutaron pruebas con los dos casos de umbral y los distintos valores de umbrales estudiados para cada uno de los casos. Se realizó de este modo, porque en principio se pensó que para distintos valores de umbral, podrían favorecer distintos valores de estos parámetros de actualización del valor de feromona. Sin embargo, se apreció que para el caso de este algoritmo, los valores para estos parámetros favorecían de igual modo la evolución del algoritmo con ambos tipos de umbral.

El conjunto completo de pruebas ejecutadas, puede observarse en el “*Anexo I: Conjunto de Pruebas y Resultados Completo*”, pero a continuación se muestra en la Tabla 11, una pequeña muestra de este ejemplo para apreciar rápidamente la deducción adquirida tras el análisis de los resultados. Para este caso, se vuelve a utilizar el caso del algoritmo de Colonia de Hormigas con 40 antenas como umbral. A su vez, y una vez que ya conocemos el número de evaluaciones más adecuado, se establece el valor de 500000 soluciones a evaluar antes de detener la ejecución del mismo.

Individuos Evaluados	Tamaño Población	Tipo	Umbral	GAMMA	ALFA	BETA	Evaluación Mejor	Fitness	Cobertura	Antenas
500000	500	Antenas	40	0.003	0.002	0.002	2528	97,61	62,48%	40
500000	500	Antenas	40	0.00003	0.00003	0.00003	171942	102,35	59,85%	35
500000	500	Antenas	40	0.03	0.02	0.02	1062	94,81	58,42%	36
500000	500	Antenas	40	0.3	0.2	0.2	988	95,54	57,82%	35
500000	500	Antenas	40	0.6	0.3	0.3	204	88,54	59,51%	40
500000	500	Antenas	40	0.9	0.6	0.6	199	84.92	57,55%	39

Tabla 11: Resultados pruebas para análisis de los valores de las constantes de actualización de feromona para el algoritmo de Colonias de Hormigas escogiendo subsolución de mayor fitness.

Se han analizado los resultados para los valores para γ , α y β de:

- a) 0.003, 0.002 y 0.002
- b) 0.00003, 0.00002 y 0.00002
- c) 0.03, 0.02 y 0.02
- d) 0.3, 0.2 y 0.2

e) 0.6, 0.3 y 0.3

f) 0.9, 0.6 y 0.6.

Con esto, y tal y como se observa en el Tabla 11, se ha llegado a la conclusión de que los valores más adecuados se corresponden con la opción b). En principio, parece una opción lógica, ya que con estos valores, se consigue que el valor de las feromonas de las 1000 localizaciones con las que se trabaja en este problema, se actualicen en base a su elección y el solapamiento tanto global como local que producen, de forma paulatina, en cantidades suficientemente pequeñas, que permitan una evolución más pausada y evitar de este modo, que desde un inicio demasiado prematuro, las hormigas se decanten por un conjunto determinado de localizaciones que han sido favorecidas inicialmente de forma arbitraria y que posiblemente no constituyan el subconjunto de enclaves óptimo para la solución al problema RND.

Por tanto, ya disponemos de los valores para los parámetros óptimos de ejecución del algoritmo, y se procede al análisis de los resultados obtenidos de las pruebas de este algoritmo para los distintos tipos de umbral.

1) Análisis estableciendo la cobertura como umbral.

Comenzamos en primer lugar con el análisis de los resultados obtenidos en el estudio del algoritmo de Colonias de Hormigas escogiendo un subconjunto de la solución de mejor fitness para resolver el problema RND, y empleando para ello un porcentaje de cobertura mínimo a alcanzar.

Teniendo en cuenta los objetivos marcados por el problema RND, de maximizar el porcentaje de cobertura proporcionada por la solución, minimizando el número de antenas empleados, se decide que resulta interesante estudiar los resultados obtenidos para el número de antenas necesarias para alcanzar una determinada cobertura mediante el algoritmo de Colonias de Hormigas. En el caso de este algoritmo, se ofrece una visión algo diferente, ya que al escoger la subsolución de mayor fitness, no se asegura que la solución final del algoritmo presente al menos el porcentaje de cobertura establecido como umbral.

En base a esta premisa, y considerando que se pretende ofrecer el máximo porcentaje de cobertura y que tratamos con un escenario donde el máximo

porcentaje de cobertura es 95,79%, se establece el estudio de la solución para 75%, 85% y 90% de cobertura como umbral a alcanzar.

Ante esta situación, se realiza un conjunto de pruebas con los valores decididos anteriormente para el tamaño de población, n° máximo de evaluaciones y constantes de actualización de la feromona para cada uno de los 3 distintos valores de umbral de cobertura.

Individuos Evaluados	Tamaño Población	Tipo	Umbral	GAMMA	ALFA	BETA	Evaluación Mejor	Fitness	Cobertura	Antenas
500000	500	Cobertura	75	0.00003	0.00003	0.00003	94364	101,47	68,32%	46
500000	500	Cobertura	85	0.00003	0.00003	0.00003	122300	104,39	65,42%	41
500000	500	Cobertura	90	0.00003	0.00003	0.00003	135705	104,55	63,03%	38

Tabla 12: Resultados pruebas de análisis del mejor valor de umbral de Cobertura para el algoritmo de Colonias de Hormigas escogiendo la subsolución de mayor fitness.

Estos resultados, pueden encontrarse resumidos en la Tabla 12, o la totalidad del conjunto en el apartado “*Anexo I: Conjunto de Pruebas y Resultados Completo*”.

Tal y como se puede observar, los mejores resultados se obtienen para el umbral del 90% de cobertura. En principio, esto puede no resultar lo más razonable, ya que se supone que a menor cobertura a alcanzar menor número de antenas a emplear de forma proporcional. Esto se debe principalmente al hecho de que se escoge la subsolución con mayor fitness, y no implica necesariamente que se trabaje con un porcentaje de al menos el 90% de cobertura en la solución final. Sin embargo, el establecer como umbral para determinar la solución de cada hormiga, un mayor porcentaje de cobertura permite realizar una mayor exploración de antenas, que ofrece una mayor posibilidad de encontrar mejores alternativas y soluciones.

Por tanto, se establece que para esta tipología del algoritmo de Colonias de Hormigas escogiendo la subsolución que ofrece mayor valor de fitness la configuración que ofrece una mejor solución es la siguiente:

- **Tamaño Población:** 500
- **Nº Máximo de Evaluaciones:** 1.000.000
- **Constantes de actualización de Feromona:**

- γ : 0.00003
- α : 0.00002
- β : 0.00002

- **Umbral Cobertura: 90%.**

, en donde se establece el número de evaluaciones a 1.000.000 para conseguir obtener mejoras en el valor del fitness, pero una vez ya que se tiene la mejor configuración.

Una vez definida la configuración paramétrica más adecuada para el algoritmo, se han realizado un conjunto de pruebas para obtener los resultados en media que produce el algoritmo con esta configuración. Para ello, se han llevado a cabo un total de 10 ejecuciones del algoritmo, con el fin de obtener la media de los valores de resultados producidos y hallar un valor medio real de lo bien que funciona el algoritmo con esta configuración, considerada la óptima.

Prueba	Individuos Evaluados	Tamaño Población	Tipo	Umbral	GAMMA	ALFA	BETA	Evaluación Mejor	Fitness	Cobertura	Antenas
1	1000000	500	Cobertura	90	0.00003	0.00002	0.00002	86712	104,25	61,26%	36
2	1000000	500	Cobertura	90	0.00003	0.00002	0.00002	188480	103,55	70,5%	48
3	1000000	500	Cobertura	90	0.00003	0.00002	0.00002	138615	103,3	62,65%	38
4	1000000	500	Cobertura	90	0.00003	0.00002	0.00002	286101	101,03	59,46%	35
5	1000000	500	Cobertura	90	0.00003	0.00002	0.00002	144096	105,56	72,65%	50
6	1000000	500	Cobertura	90	0.00003	0.00002	0.00002	41474	105,37	68,09%	44
7	1000000	500	Cobertura	90	0.00003	0.00002	0.00002	132348	103,4	68,96%	46
8	1000000	500	Cobertura	90	0.00003	0.00002	0.00002	144153	101,63	59,64%	35
9	1000000	500	Cobertura	90	0.00003	0.00002	0.00002	146524	101,71	68,4%	46
10	1000000	500	Cobertura	90	0.00003	0.00002	0.00002	159412	105,32	70,35%	47

Tabla 13: Resultados Mejor Configuración Algoritmo Colonias de Hormigas escogiendo subsolución con mayor valor de fitness y porcentaje de cobertura como umbral.

Los resultados de estas pruebas pueden encontrarse en la Tabla 13. En esta podemos observar que el mayor valor de fitness alcanzado tiene un valor de **105.56**, obtenido como resultado de la aplicación de la fórmula de la función de adaptación para un **72,65% de cobertura** utilizando un total de **50 antenas**. La

representación de esta solución puede encontrarse asimismo, en la Ilustración 32.

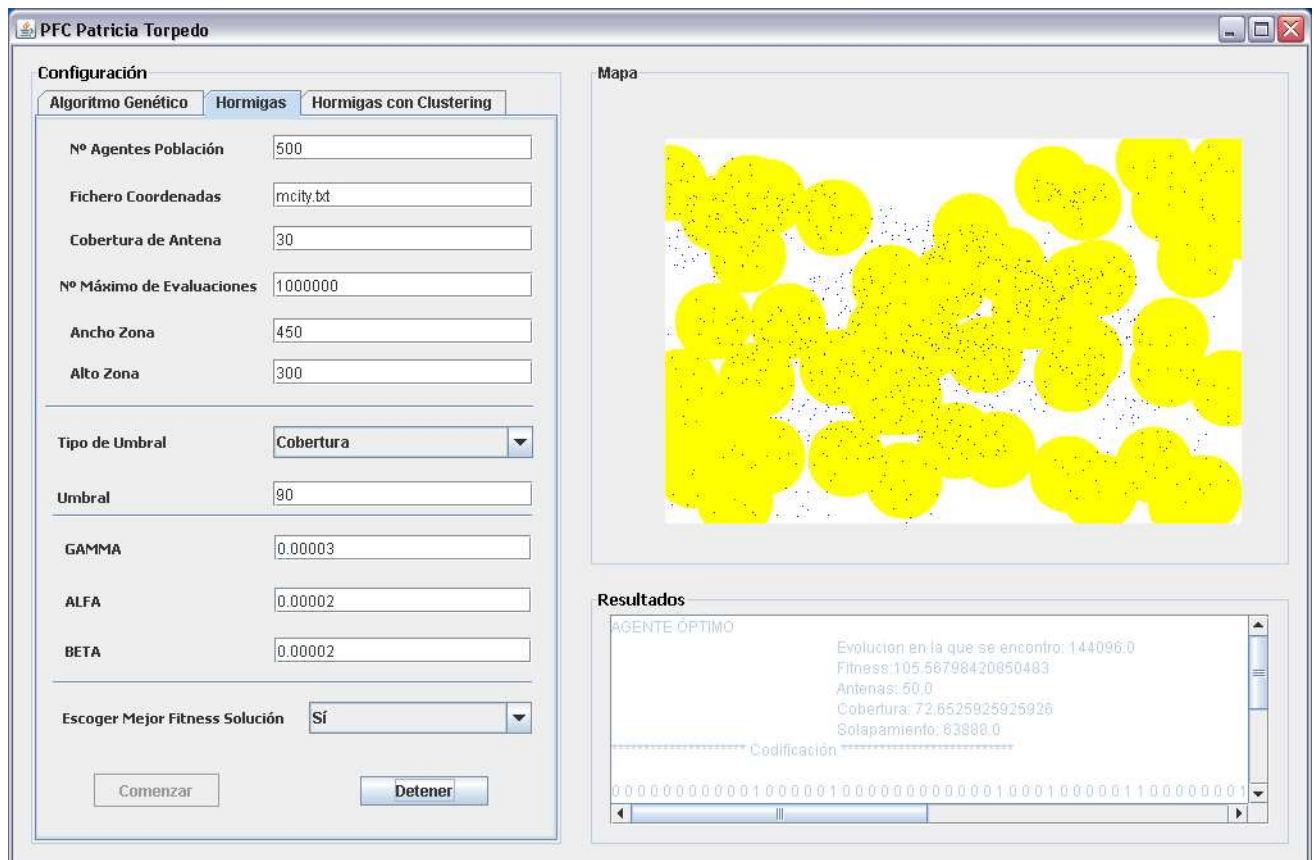


Ilustración 30: Mejor resultado del algoritmo de Colonias de Hormigas Modificado con Cobertura como umbral.

Por el funcionamiento desarrollado para este algoritmo de Colonias de Hormigas, las hormigas de la población se centran en un principio, en seleccionar posiciones donde localizar antenas en base al valor de feromona de cada una de ellas de forma iterativa hasta alcanzar el umbral de cobertura preestablecido, para finalmente obtener el subconjunto de solución con mayor valor de fitness. A partir de este momento, y en base a la solución final obtenida, se actualizan los valores de feromona para cada una de las localizaciones de antenas. De esta forma, el algoritmo se centra en escoger localizaciones de antenas en base a la cantidad de veces que se hayan seleccionado para la solución, y esto implica que finalmente, todas las hormigas escojan siempre el subconjunto de posiciones más visitadas de forma muy temprana en las generaciones, pudiendo dejar al margen localizaciones que posiblemente resultasen mejores. Esto, provoca que las soluciones obtenidas no ofrezcan

resultados de fitness tan buenos como los alcanzados con los AG's, pero sin embargo, permiten un estudio diferente del problema con una serie de restricciones, como es el caso de obtener un porcentaje de cobertura mínimo y a partir de ahí obtener la solución, que ofrecen visiones del problema más exactas que permiten conocer en mayor medida la relación existente entre porcentaje de cobertura y nº de antenas empeladas.




Gráfico 7: N° de Antenas Resultados RNDHormigas Modificado con la Configuración Óptima y cobertura como umbral.




Gráfico 8: Porcentaje de Cobertura Resultados RNDHormigas Modificado con la Configuración Óptima y cobertura como umbral.




Gráfico 9: Fitness Resultados RNDHormigas Modificado con Configuración Óptima y cobertura como umbral.

En los Gráficos 7,8 y 9, se observa de forma rápida y visual los resultados de N° de Antenas, Porcentaje de Cobertura y Valor de Fitness respectivamente, para las 10 ejecuciones realizadas con la configuración obtenida como óptima para el algoritmo de Colonias de Hormigas Modificado con cobertura como umbral. Con estos gráficos podemos observar cómo para el caso del fitness se obtienen siempre valores comprendidos en el rango [101, 106], para el caso del número de antenas empleadas entre [35,50]; y por último, en el caso del porcentaje de la cobertura, los valores se encuentran dentro del rango de valores [59, 73]. Se ha incluido el gráfico de cobertura, ya que a pesar de imponer que la solución debe alcanzar una cobertura mínima del 90% en principio, al escoger la subsolución de mayor fitness varían en mayor rango estos valores.

Ante esta circunstancia de resultados muy semejantes para las distintas ejecuciones realizadas, y observando el Gráfico de dispersión de los resultados, podemos apreciar cómo se consigue para esta configuración del algoritmo de Colonias de Hormigas Modificado con cobertura como umbral, unos valores medios aproximados de **42 antenas, 66% de cobertura y un 103 de fitness.**

Se advierte que en ninguno de los casos de las pruebas ejecutadas, el número de antenas supera el valor de 50. Esto supone un indicador muy relevante, ya que las antenas empleadas representan un factor muy influyente para el fitness final. Siendo así, el algoritmo debe ocuparse de obtener la solución de mayor cobertura empleando un n° de antenas dentro de este rango.




Gráfico 10: Resultados RNDHormigas Modificado Cobertura con la Configuración Óptima.

Con los resultados mostrados en el Gráfico 11, se puede observar la evolución de las soluciones que va produciendo la ejecución del algoritmo de Colonias de Hormigas escogiendo la subsolución con mayor fitness en el caso de emplear la cobertura como umbral. Mucho de lo comentado con anterioridad acerca del funcionamiento de este algoritmo, se puede apreciar en mayor medida al observar estos datos. Se puede advertir a simple vista, como la evolución del valor del fitness de las soluciones generadas a lo largo del algoritmo no van en continuo incremento, si no que al principio se produce un aumento paulatino de este valor que comienza a caer al final en lugar de continuar creciendo, a pesar de que se observan unos puntos más altos en determinados intervalos de la ejecución del algoritmo.

En base al funcionamiento general del algoritmo, se considera que esto ocurre de este modo, ya que desde la primera hormiga que genera una solución,

se van actualizando la feromona de cada una de las posibles antenas a emplazar, y esto provoca, que las hormigas que le siguen tengan desde muy temprano una inclinación clara para seleccionar antenas ya utilizadas por otra hormiga para su solución. Si además, se tiene en cuenta que las primera antenas se seleccionan de forma aleatoria y que no tienen porque ser las más adecuadas, se advierte cierta lógica en el hecho de que tras un importante número de evaluaciones, exista un conjunto de antenas que reúnen entre ellas casi la totalidad del porcentaje de selección, lo que provoca que se produzca un estancamiento en la elección. Todo esto viene influido en el hecho de que el subconjunto de solución que la hormiga toma como solución final, viene determinado por el orden inicial de elección de antenas realizado por la hormiga, y de este modo, podemos dejar sin escoger antenas que mejorarían notablemente el resultado, simplemente por haber sido escogidas más tarde que otra, y que quizás únicamente aumenta el solapamiento, ofreciendo un mínimo aumento en el porcentaje de cobertura.

En lo referente a la evolución del valor de las antenas, se puede observar cómo se mantiene siempre en el mismo rango. Esto mismo ocurre con el porcentaje de cobertura que no presenta grandes desviaciones o variaciones en su valor. Además, se puede apreciar como el comportamiento de las líneas de evolución del porcentaje de cobertura y el número de antenas es exactamente el mismo; cuando uno aumenta, el otro también de forma proporcional. Esta situación hace pensar que durante toda la ejecución, el algoritmo se ha dedicado a buscar entre las alternativas disponibles la mejor combinación de porcentaje de cobertura/nº de antenas.




Gráfico 11: Evolución Mejor Solución RNDHormigas Modificado Cobertura mostrando los resultados de la mejor solución de cada población (Eje X: Población).

2) *Análisis estableciendo el número de antenas como umbral.*

A continuación, se procede a explicar los resultados obtenidos de las pruebas del algoritmo de Colonias de Hormigas escogiendo el subconjunto de mejor fitness de la solución para la resolución del problema RND, empleando para ello un número mínimo de antenas a utilizar en la solución.

En este caso, se pretende estudiar los resultados que podemos obtener en lugar de fijando la cobertura mínima que se pretende alcanzar inicialmente, estableciendo un número máximo de antenas a emplazar y observar de este modo, cual es el máximo porcentaje de cobertura que se puede obtener con X antenas. Resulta un punto de vista muy interesante para la resolución del problema RND, para casos en los que se determine que de entre un número Y, muy elevado de posibles localizaciones, únicamente se pueda diseñar la red de telefonía con un número X de antenas máximas mucho menor que Y.

Ante esta circunstancia, y en base al escenario concreto de Málaga con el que se está trabajando, se decidió realizar pruebas para analizar los resultados

obtenidos con un máximo de 40, 50 y 60 antenas. Por tanto, para este algoritmo, se generaron ejecuciones con estos valores como umbral.

Con esto, se realiza un conjunto de pruebas con los valores decididos anteriormente para el tamaño de población, nº máximo de evaluaciones y constantes de actualización de la feromona para cada uno de los 3 distintos valores de umbral de nº de antenas.

Individuos Evaluados	Tamaño Población	Tipo	Umbral	GAMMA	ALFA	BETA	Evaluación Mejor	Fitness	Cobertura	Antenas
500000	500	Antenas	40	0.00003	0.00003	0.00003	171942	102,35	59,85%	35
500000	500	Antenas	50	0.00003	0.00003	0.00003	153715	102,72	67,23%	44
500000	500	Antenas	60	0.00003	0.00003	0.00003	166621	103,702	65,99%	42

Tabla 14: Resultados pruebas de análisis del mejor valor de umbral de Antenas para el algoritmo de Colonias de Hormigas escogiendo la subsolución de mayor fitness.

Estos resultados, pueden encontrarse resumidos en la Tabla 14, o la totalidad del conjunto en el apartado “*Anexo I: Conjunto de Pruebas y Resultados Completo*”.

Tal y como se puede observar, los mejores resultados se obtienen para el umbral de 60 antenas a emplear como máximo. Como se puede apreciar en la Tabla 14, el nº final de antenas que emplea cada solución no difiere en una gran cantidad, de hecho, incluso la opción de 60 antenas como umbral emplea un menor número de ellas en la solución final que la obtenida con el umbral de 50 antenas. Si comparamos las soluciones de 40 y 60 antenas como umbral, observamos como al permitir emplear más, se consigue un aumento de cobertura suficiente como para poder emplear un mayor número de antenas y además mejorar el fitness. Ahora bien, al comparar las soluciones de 40 y 50 antenas como umbral, se observa que el hecho de conseguir aumentar la cobertura a costa de emplear casi 10 antenas más no compensa ya que el fitness obtenido es muy similar.

El hecho de que la mejor solución se obtenga de establecer un número de antenas mayor (60 en este caso), se justifica por un motivo obvio, y es que al

imponer a la hormiga que busque inicialmente una solución con 60 antenas, aunque luego se pueda disminuir, permite que el número de posibles localizaciones de antenas explorados también sea mayor, y de este modo, obtener una visión más real de las alternativas con las que poder trabajar. Sin tener esto en cuenta, y observando que al final la hormiga selecciona como solución final el subconjunto de mayor fitness de la solución inicial, podría resultar ilógico, ya que el problema busca maximizar la cobertura minimizando el número de antenas empleadas, pero es por esta razón de selección de subconjunto que al establecer un umbral mayor, siempre dentro del rango razonable, se ofrece mayor exploración y por tanto una mayor gama de alternativas.

Por tanto, se establece que para esta tipología del algoritmo de Colonias de Hormigas escogiendo la subsolución que ofrece mayor valor de fitness, la configuración que obtiene una mejor solución es la siguiente:

- **Tamaño Población:** 500
- **Nº Máximo de Evaluaciones:** 1.000.000
- **Constantes de actualización de Feromona:**
 - γ : 0.00003
 - α : 0.00002
 - β : 0.00002
- **Umbral Antenas:** 60.

Con la configuración paramétrica más adecuada para el algoritmo ya establecida, se realizaron un conjunto de pruebas para obtener los resultados en media que produce el algoritmo con esta configuración. Para ello, se han llevado a cabo un total de 10 ejecuciones del algoritmo, con el fin de obtener la media de los valores de resultados producidos y hallar un valor medio real de cómo de bien funciona con el algoritmo con esta configuración, considerada la óptima.

Prueba	Individuos Evaluados	Tamaño Población	Tipo	Umbral	GAMMA	ALFA	BETA	Evaluación Mejor	Fitness	Cobertura	Antenas
1	1000000	500	Antenas	60	0.00003	0.00002	0.00002	120710	103,31	71,87%	50
2	1000000	500	Antenas	60	0.00003	0.00002	0.00002	204039	102,83	57,36%	32
3	1000000	500	Antenas	60	0.00003	0.00002	0.00002	149681	103,14	63,42%	39
4	1000000	500	Antenas	60	0.00003	0.00002	0.00002	140668	101,51	74,03%	54
5	1000000	500	Antenas	60	0.00003	0.00002	0.00002	186651	104,66	68,62%	45
6	1000000	500	Antenas	60	0.00003	0.00002	0.00002	123960	101,73	66,14%	43
7	1000000	500	Antenas	60	0.00003	0.00002	0.00002	173271	102,13	64,71%	41
8	1000000	500	Antenas	60	0.00003	0.00002	0.00002	121784	105,034	76,005%	55
9	1000000	500	Antenas	60	0.00003	0.00002	0.00002	152386	102,1	72,16%	51
10	1000000	500	Antenas	60	0.00003	0.00002	0.00002	197378	104,056	69,18%	46

Tabla 15: Resultados Mejor Configuración Algoritmo Colonias de Hormigas escogiendo subsolución con mayor valor de fitness y antenas como umbral.

Los resultados de estas pruebas pueden encontrarse en la Tabla 15. En esta podemos encontrar que el mayor valor de fitness alcanzado tiene un valor de **105.034**, obtenido como resultado de la aplicación de la fórmula de la función de adaptación para un **76,005% de cobertura** utilizando un total de **55 antenas**. Asimismo, la representación de esta solución puede encontrarse en la Ilustración 33.

que sea imposible encontrar soluciones más adecuadas, al dejar sin explorar posiciones cuyo uso resultase óptimo.

Al igual que ocurría con el caso de la cobertura como umbral, esta situación provoca que las soluciones obtenidas con este algoritmo, no ofrezcan resultados de fitness tan adecuados como los alcanzados con los AG's, pero del mismo modo, ofrecen la posibilidad de realizar un análisis del problema RND desde una perspectiva diferente donde estudiar el porcentaje de cobertura máximo que se puede conseguir empleando un número máximo de antenas.




Gráfico 12: N° de Antenas Resultados RNDHormigas Modificado con la Configuración Óptima y antenas como umbral.




Gráfico 13: Porcentaje de Cobertura Resultados RNDHormigas Modificado con la Configuración Óptima y antenas como umbral.




Gráfico 14: Fitness Resultados RNDHormigas Modificado con Configuración Óptima y antenas como umbral.

En los Gráficos 12, 13 y 14, se observa de forma rápida y visual los resultados de N° de Antenas, Porcentaje de Cobertura y Valor de Fitness respectivamente, para las 10 ejecuciones realizadas con la configuración obtenida como óptima para el algoritmo de Colonias de Hormigas Modificado

con antenas como umbral. Con estos gráficos podemos observar cómo para el caso del fitness se obtienen siempre valores comprendidos en el rango [101, 105], para el caso del número de antenas empleadas entre [32,55]; y por último, en el caso del porcentaje de la cobertura, los valores se encuentran dentro del rango [57, 76]. Se ha incluido el gráfico de nº de antenas, ya que a pesar de imponer que la solución debe emplear un total de 60 en principio, al escoger la subsolución de mayor fitness varían en mayor rango estos valores.

Ante esta circunstancia de resultados muy semejantes para las distintas ejecuciones realizadas, y observando el Gráfico 15 de dispersión de los resultados, podemos apreciar cómo se consigue para esta configuración del algoritmo de Colonias de Hormigas Modificado con antenas como umbral unos valores medios aproximados de **46 antenas, 68% de cobertura y un 103 de fitness.**

Se advierte que en ninguno de los casos de las pruebas ejecutadas, el número de antenas supera el valor de 55, que es el empleado en la obtención de la mejor solución. Puede resultar extraño que la mejor solución obtenida se trate de la que emplea un mayor número de antenas, cuando lo que se pretende es minimizar el número empleado de éstas. Sin embargo, se debe a que el porcentaje de cobertura es lo suficientemente más elevado que el resto, como para que compense el uso de este mayor nº de antenas.




Gráfico 15: Resultados RNDHormigas Modificado Antenas con la Configuración Óptima.

Con los resultados mostrados en el Gráfico 16, se puede observar la evolución de las soluciones que va produciendo la ejecución del algoritmo de Colonias de Hormigas escogiendo la subsolución con mayor fitness en el caso de emplear el nº de antenas como umbral. Las conclusiones que se pueden obtener de este caso son prácticamente las mismas que en el caso de la cobertura como umbral.

Se observa como la evolución del valor del fitness de las soluciones generadas a lo largo del algoritmo no tiene un incremento continuo, si no que al principio se produce un aumento paulatino de este valor que comienza a caer al final en lugar de continuar creciendo, a pesar de que se observan unos puntos más altos en determinados intervalos de la ejecución. Tal y como ya se ha comentado, esto ocurre debido a la prematura predisposición hacia un conjunto de antenas determinado, que no se ha conseguido evitar al variar los valores de la constantes de actualización de las feromonas de las localizaciones de las antenas.

En lo referente a la evolución del valor de las antenas, y como en el caso anterior del umbral en base al porcentaje de la cobertura, se observa cómo se mantiene siempre en el mismo rango, sin aumentar demasiado. Lo mismo ocurre con el porcentaje de cobertura que no presenta grandes desviaciones o variaciones en su valor, a pesar que se aprecia un ligero descenso hacia el final de la ejecución del algoritmo, que sin embargo no resulta relevante, ya que se ve acompañado de un decremento proporcional del número de antenas. Por tanto, el algoritmo se ha dedicado a buscar entre las alternativas disponibles, la mejor combinación de porcentaje de cobertura/nº de antenas.




Gráfico 16: Evolución Mejor Solución RNDHormigas Modificado Antenas mostrando los resultados de la mejor solución de cada población (Eje X: Población).

5.3 Resultados y Análisis del Algoritmo de Colonias de Hormigas Original.

Observados los resultados obtenidos con la versión del Algoritmo de Colonias de Hormigas Modificado, a continuación se procede a analizar los resultados de las pruebas con el Algoritmo de Colonias de Hormigas original, estableciendo para la hormiga el objetivo de alcanzar un umbral mínimo impuesto al comienzo de la ejecución del algoritmo, y no se seleccionará como en el caso anterior, el subconjunto de la solución que proporcione mayor fitness.

Al igual que en el apartado anterior, el estudio de este algoritmo se realizará mediante dos análisis diferentes: 1) Para el número de antenas como umbral y 2) Para la cobertura como umbral.

En base a los resultados obtenidos en el apartado anterior “5.3 Resultados y Análisis del Algoritmo de Colonias de Hormigas Escogiendo Mejor Fitness de la Solución”, acerca del valor de nº de evaluaciones máximo, se utilizará el número de 1.000.000 evaluaciones directamente, ya que se ha observado que en ocasiones consigue mejorar lo suficiente el valor del fitness.

En cuanto a los valores de γ , α y β más adecuados para la generación de soluciones óptimas al problema RND mediante el algoritmo de Colonias de Hormigas Original, se ha decidido repetir el estudio y no emplear los obtenidos en el caso anterior, ya que al modificar la solución escogida era posible que los valores más adecuados difirieran.

En base al conocimiento adquirido con el estudio anterior, mediante el cual ya se conocía que los valores de actualización de feromona no suponían un cambio significativo ante los dos tipos de umbral, se ejecutaron pruebas únicamente para el caso del número de antenas como umbral. De este modo, se muestra en la Tabla 19, los resultados de las ejecuciones del algoritmo con 40 antenas como umbral, para los distintos valores de γ , α y β .

Individuos Evaluados	Tamaño Población	Tipo	Umbral	GAMMA	ALFA	BETA	Evaluación Mejor	Fitness	Cobertura	Antenas
1000000	500	Antenas	40	0.0000000003	0.0000000002	0.0000000002	30642	98,22	62,68%	40
1000000	500	Antenas	40	0.0000000003	0.0000000002	0.0000000002	997970	95,84	61,91%	40
1000000	500	Antenas	40	0.0000000003	0.0000000002	0.0000000002	258140	96,66	62,18%	40
1000000	500	Antenas	40	0.00000003	0.00000002	0.00000002	92576	99,65	63,13%	40
1000000	500	Antenas	40	0.0000003	0.0000002	0.0000002	850664	102,12	63,91%	40
1000000	500	Antenas	40	0.000003	0.000002	0.000002	177431	106,34	65,22%	40
1000000	500	Antenas	40	0.0003	0.0002	0.0002	19614	98,11	62,64%	40

Tabla 16: Resultados del análisis de los valores de las constantes de actualización de feromona para el algoritmo de Colonias de Hormigas Original.

Se han analizado los resultados para los valores para γ , α y β de:

- a) 0.0000000003, 0.0000000002 y 0.0000000002
- b) 0.0000000003, 0.0000000002 y 0.0000000002
- c) 0.0000000003, 0.0000000002 y 0.0000000002
- d) 0.00000003, 0.00000002 y 0.00000002
- e) 0.0000003, 0.0000002 y 0.0000002
- f) 0.000003, 0.000002 y 0.000002.
- g) 0.0003, 0.0002 y 0.0002

Con esto, y tal y como se observa en el Tabla 16, se ha llegado a la conclusión de que los valores más adecuados se corresponden con la opción f). Se observa que coincide exactamente con los establecidos como óptimos en el estudio del Algoritmo de Colonias de Hormigas Modificado. Por tanto, podemos decir que con estos valores, se consigue que, el valor de las feromonas de las 1.000 localizaciones con las que se trabaja en este problema, se actualicen en base a su elección y el solapamiento tanto global como local que producen, consiguiendo una evolución paulatina. De este modo, se evita que desde un momento demasiado prematuro, las hormigas se decanten por un conjunto determinado de localizaciones que han sido favorecidas inicialmente de forma arbitraria y que posiblemente no constituyan el subconjunto de enclaves óptimo para la solución al problema RND.

Ya disponemos de los valores para los parámetros óptimos de ejecución del algoritmo, y se procede al análisis de los resultados obtenidos de las pruebas de este para los distintos tipos de umbral.

1) Análisis estableciendo el número de antenas como umbral.

Con los parámetros comunes a ambos umbrales para el algoritmo de Colonias de Hormigas Original, se procede a analizar los resultados que se obtienen mediante la ejecución de este algoritmo para cada tipo de umbral, que en este caso, será por el número de antenas a emplear.

Para esto, recordar que este algoritmo para cada solución inicial generada por cada una de las hormigas, no seleccionará como solución final el subconjunto de mayor fitness; la solución final será la establecida por la hormiga de manera inicial para alcanzar el umbral establecido.

De este modo, y en este caso del número de antenas como umbral, lo que se busca es conocer el porcentaje de cobertura máximo que se puede alcanzar utilizando para ello exactamente un número X de antenas. Este algoritmo, proporciona una perspectiva diferente en la resolución del problema RND, ya que si en casos anteriores buscábamos conocer la mejor solución que podíamos alcanzar empleando como máximo un número determinado de antenas, ahora buscamos conocer el porcentaje máximo de cobertura que se puede establecer con el emplazamiento de un número exacto de antenas.

Teniendo en cuenta el escenario concreto de Málaga con el que se está trabajando, se decidió realizar pruebas para analizar los resultados obtenidos con un 40, 45, 50, 55, 60 y 65 antenas. Por tanto, para este algoritmo, se generaron ejecuciones con estos valores como umbral.

Con estos valores de umbral y los del resto de parámetros del algoritmo como el tamaño de población, número máximo de evaluaciones y las constantes de actualización de la feromona, decididos con anterioridad, se ejecutan un conjunto de pruebas, cuyos resultados se muestran en la Tabla 17, a fin de determinar la mejor opción de umbral para este algoritmo en concreto.

Individuos Evaluados	Tamaño Población	Tipo	Umbral	GAMMA	ALFA	BETA	Evaluación Mejor	Fitness	Cobertura	Antenas
1000000	500	Antenas	40	0.00003	0.00002	0.00002	177431	106,34	65,22%	40
1000000	500	Antenas	45	0.00003	0.00002	0.00002	222125	103,06	68,1%	45
1000000	500	Antenas	50	0.00003	0.00002	0.00002	175112	101,32	71,17%	50
1000000	500	Antenas	55	0.00003	0.00002	0.00002	205253	100,16	74,22%	55
1000000	500	Antenas	60	0.00003	0.00002	0.00002	164364	95,77	75,8%	60
1000000	500	Antenas	65	0.00003	0.00002	0.00002	99447	94,93	78,55%	65

Tabla 17: Resultados de las pruebas de análisis del mejor valor de umbral de Antenas por el algoritmo de Colonias de Hormigas Original.

Observando los resultados obtenidos en la Tabla 17, se puede apreciar como a medida que se aumenta el número de antenas a emplear en la solución, aumenta también el porcentaje de cobertura, pero sin embargo no de forma proporcional y suficiente al aumento producido en el número de antenas, ya que el valor de la función de fitness, decrece de forma paulatina.

Por tanto, se puede decir que este método del algoritmo, resulta muy interesante para poder realizar estudios sobre qué cobertura se puede conseguir empleando un número determinado de antenas, pero para el estudio que nos ocupa, relativo a encontrar la mejor solución, se establece que la mejor opción de umbral es de 40 antenas, ya que a pesar de proporcionar una menor cobertura que el resto, su valor de fitness es superior de forma considerable al resto.

Se establece, de este modo que, para esta tipología del algoritmo de Colonias de Hormigas Original, la configuración que ofrece una mejor solución es la siguiente:

- **Tamaño Población:** 500
- **Nº Máximo de Evaluaciones:** 1000000
- **Constantes de actualización de Feromona:**
 - γ : 0.00003
 - α : 0.00002
 - β : 0.00002
- **Umbral Antenas:** 40.

Ya determinada la configuración paramétrica del algoritmo de Colonias de Hormigas que ofrece un mayor valor de fitness, se ejecuta, en este caso, únicamente una prueba con esta configuración óptima. Para este algoritmo, se ejecuta una sola prueba, ya que se conoce desde el principio que los resultados que podemos obtener con él no van a ser los mejores y solo se pretende obtener una visión general de su funcionamiento y resultado.

Individuos Evaluados	Tamaño Población	Tipo	Umbral	GAMMA	ALFA	BETA	Evaluación Mejor	Fitness	Cobertura	Antenas
1000000	500	Antenas	40	0.00003	0.00002	0.00002	177431	106,34	65,22%	40

Tabla 18: Resultado de la mejor configuración del algoritmo de Colonias de Hormigas Original con mayor valor de fitness y antenas como umbral.

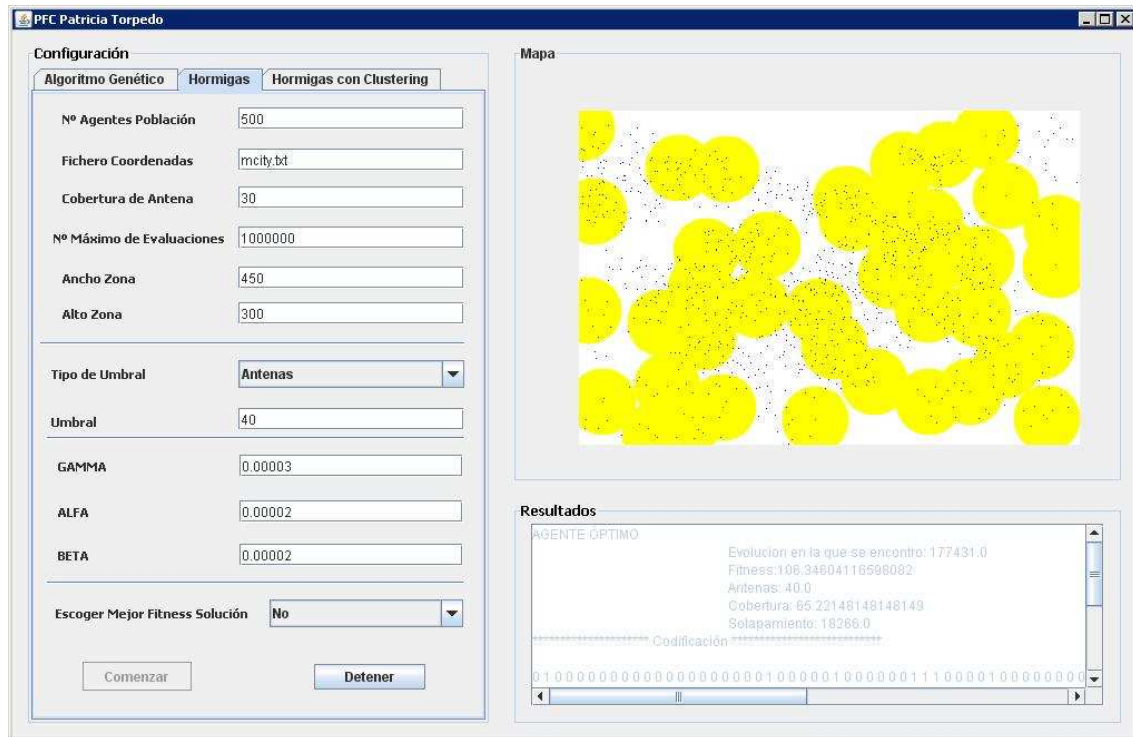


Ilustración 32: Mejor resultado del algoritmo de Colonias de Hormigas Original con antenas como umbral.

Los resultados de esta prueba pueden encontrarse en la Tabla 18. En esta tabla, y en la Ilustración 34, se observa que el fitness alcanzado tiene un valor de **106,34**, obtenido como resultado de la aplicación de la fórmula de la función de adaptación para un **65,22% de cobertura** utilizando un total de **40 antenas**.

Para este tipo de algoritmo, ocurre exactamente lo mismo que para el algoritmo de Colonias de Hormigas Modificado, y es que debido a que la selección inicial de los posibles emplazamientos de las antenas se realiza de forma aleatoria, no se explora lo suficiente todas las alternativas y no se obtienen resultados óptimos. Todo esto, provoca que las hormigas se centren rápidamente en un conjunto de antenas determinado y puedan dejarse sin explorar posiciones óptimas que por razones de aleatoriedad no tengan una alta probabilidad de selección.

Así, puede decirse que este tipo de algoritmos no son los mejores para encontrar la solución óptima al problema, pero si resultan útiles para estudiar el problema RND desde perspectivas diferentes.

Del mismo modo que se realizó en el estudio del algoritmo de Colonias de Hormigas Modificado, se muestra en el Gráfico 17 la evolución que ha tenido el algoritmo, a lo largo de su ejecución, en el caso de la mejor solución encontrada. Esto permite observar cómo van trabajando las hormigas y las soluciones que van generando a medida que se actualiza el valor de la feromona o probabilidad de selección de las localizaciones de las antenas.

Ya que estamos estudiando el caso del algoritmo en el que se quiere analizar el porcentaje máximo de cobertura que se puede alcanzar empleando un número determinado de antenas, se observa como a lo largo de toda la ejecución el valor del número de antenas permanece completamente constante en 45.

A partir de esto, se analiza el porcentaje de cobertura que se obtiene. Si observamos el gráfico, se ve claramente como de forma inicial el porcentaje de cobertura se mantiene, aumentando de forma mínima, pero a partir de la población 500 aproximadamente comienza a decrecer de forma continua para finalmente estancarse en unos valores de porcentaje cercanos al 50%.

Al estudiar todos los datos producidos por el algoritmo, se ha concluido que este comportamiento viene determinado por la actualización de feromona de las antenas. Ya que se trabaja con un gran número de posibles localizaciones, la probabilidad de cada antena de ser seleccionada es muy pequeña. Al principio de la ejecución del algoritmo, no supone demasiado problema, ya que todas tienen aproximadamente la misma probabilidad. Sin embargo, según se van

seleccionando con mayor frecuencia unas determinadas antenas (y no todas tienen que ser adecuadas), se produce una situación en la que unas pocas aglutinan la mayor cantidad de porcentaje de selección, mientras que el resto tienen un valor muy pequeño de feromona.

Si atendemos a la posibilidad de que no se hallan favorecido de forma inicial a las mejores antenas, ya que la selección en un inicio es completamente aleatoria, entendemos los resultados obtenidos y el comportamiento del algoritmo: se encuentra en una situación en la que no es capaz de hallar buenas soluciones, ya que está trabajando con antenas que considera las mejores, pero que en realidad no ofrecen los resultados óptimos.

En cuanto al comportamiento del fitness, representa el mismo que el porcentaje de cobertura, ya que al permanecer constante el número de antenas empleadas, el único valor que varía el resultado de la función de fitness es la cobertura. De este modo, el fitness aumenta cuando lo hace la cobertura, y disminuye también con ésta.




Gráfico 17: Evolución de la mejor solución de RNDHormigas Original con Antenas como umbral, mostrando los resultados de la mejor solución de cada población (Eje X: Población).

2) *Análisis estableciendo la cobertura como umbral.*

A continuación, y con los parámetros comunes a ambos umbrales para el algoritmo de Colonias de Hormigas Original, se desarrollará el estudio de las soluciones obtenidas con la ejecución de este algoritmo para el caso de empleo del porcentaje de cobertura como umbral.

Si recordamos que este algoritmo no seleccionará el subconjunto de mayor fitness de la solución encontrada por la hormiga, se puede decir que mediante este análisis lo que se busca es conocer el número de antenas mínimas a emplear para conseguir proporcionar un determinado porcentaje de cobertura.

Con esta versión del algoritmo, se ofrece una visión novedosa para la resolución del problema RND. Ahora no buscamos obtener una combinación cualquiera de porcentaje de cobertura y nº de antenas que ofrezca el mayor valor de fitness, si no que se pretende realizar un estudio únicamente sobre el número de antenas necesarias para la solución, imponiendo un porcentaje de cobertura mínimo que obtener.

Atendiendo al escenario concreto de Málaga con el que se trabaja, se decidió realizar pruebas para analizar los resultados obtenidos con un porcentaje de cobertura mínimo de 75, 85 y 90%. Por tanto, para este algoritmo, se generaron ejecuciones con estos valores como umbral.

Se realizaron, por tanto, un conjunto de pruebas con los parámetros del algoritmo decididos de forma global para ambos umbrales sobre el tamaño de población, número máximo de evaluaciones y las constantes de actualización de feromona, así como con los distintos valores de umbral que se pretendían estudiar. Los resultados de estas pruebas se muestran en la Tabla 19.

Individuos Evaluados	Tamaño Población	Tipo	Umbral	GAMMA	ALFA	BETA	Evaluación Mejor	Fitness	Cobertura	Antenas
1000000	500	Cobertura	75	0.00003	0.00002	0.00002	286043	98,18	75,46%	58
1000000	500	Cobertura	85	0.00003	0.00002	0.00002	986294	88,86	85,88%	83
1000000	500	Cobertura	90	0.00003	0.00002	0.00002	959171	69,98	90,104%	116

Tabla 19: Resultados de las pruebas de análisis del mejor valor de umbral de porcentaje de cobertura para el algoritmo de Colonias de Hormigas Original.

Observando los resultados obtenidos en la Tabla 19, se aprecia como el incremento en el porcentaje de cobertura mínimo que debe alcanzar la solución de la hormiga, implica un aumento enorme en el número de antenas empleadas. Este incremento tan significativo provoca que a su vez, el fitness disminuya de forma proporcional, obteniendo de este modo, peores soluciones.

Tras el análisis de los resultados, se llegó a la conclusión de que la razón de que el número de antenas necesarias fuese tan elevado, se debía a que como inicialmente la selección de las mismas se realiza de forma aleatoria, para conseguir los porcentajes de cobertura impuestos, se utilizan de forma inicial un gran número de éstas, ya que no se conoce a priori cuales son mejores. Este hecho provoca que las sucesivas hormigas encuentren gran dificultad en emplear un menor número de antenas, ya que de forma previa han empezado a obtener mayor valor de feromona algunas antenas que no son las óptimas y cuya selección únicamente supone un decremento en el valor de fitness y aumenta el solapamiento de la solución.

Con esto, se puede concluir que si bien esta versión del algoritmo puede resultar muy llamativa para estudiar el número aproximado de antenas necesarias para cubrir un determinado porcentaje de cobertura, para el estudio que nos ocupa, sobre obtener las soluciones más adecuadas, no resulta aconsejable.

Fijándonos de nuevo en la Tabla 19, se observa como la solución que proporciona un mayor valor de fitness es aquella en la que se emplea un 75% de cobertura como umbral.

Se establece, de este modo, que para esta tipología del algoritmo de Colonias de Hormigas Original, la configuración que ofrece una mejor solución es la siguiente:

- **Tamaño Población:** 500
- **Nº Máximo de Evaluaciones:** 1000000
- **Constantes de actualización de Feromona:**
 - γ : 0.00003
 - α : 0.00002
 - β : 0.00002
- **Umbral Cobertura:** 75.

Para el caso de este algoritmo, no se realizó un conjunto de pruebas con la configuración óptima, ya que las ejecuciones para este caso podían tener un coste temporal de unas 48 horas, y teniendo en cuenta que los resultados obtenidos con dicho algoritmo, no iban a ofrecer las soluciones óptimas sobre el valor de fitness que buscamos, se decidió no consumir más tiempo en el estudio de éste, y analizar directamente el resultado de la prueba ejecutada con dicha configuración realizada de forma previa para el análisis del umbral.

Individuos Evaluados	Tamaño Población	Tipo	Umbral	GAMMA	ALFA	BETA	Evaluación Mejor	Fitness	Cobertura	Antenas
1000000	500	Cobertura	75	0.00003	0.00002	0.00002	286043	98,18	75,46%	58

Tabla 20: Resultado de la mejor configuración para el algoritmo de Colonias de Hormigas Original con mayor valor de fitness y porcentaje de cobertura como umbral.

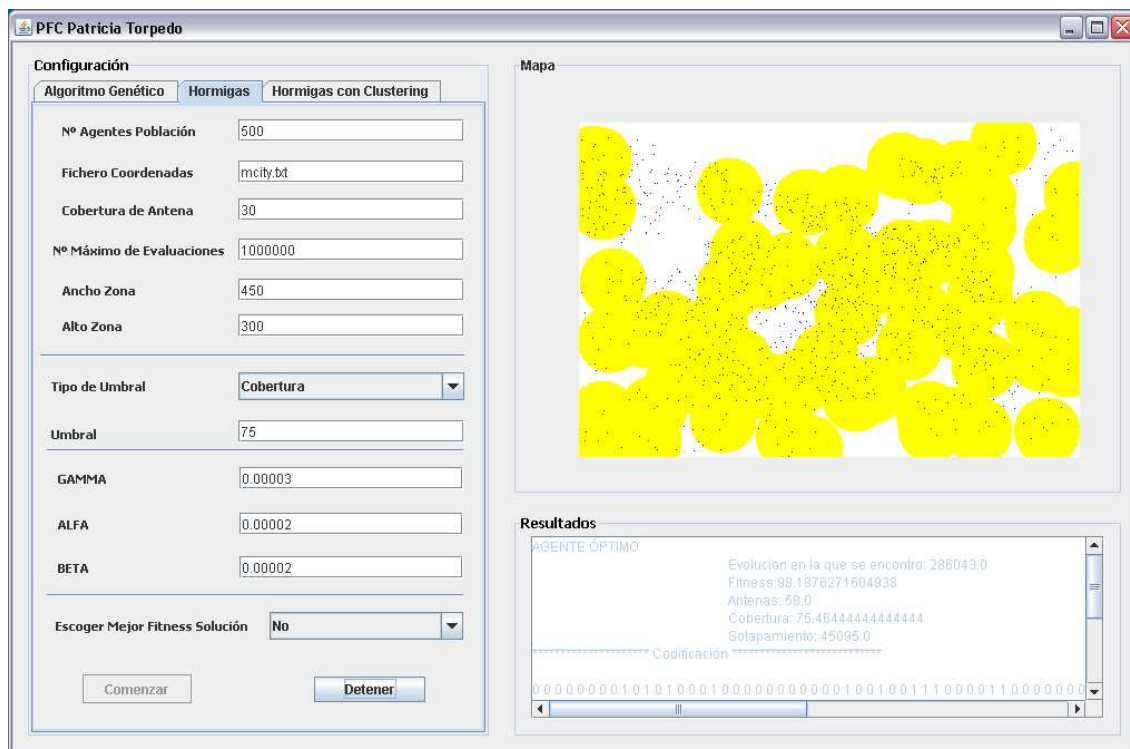


Ilustración 33: Mejor resultado del algoritmo de Colonias de Hormigas Original con porcentaje de cobertura como umbral.

Los resultados de esta prueba pueden encontrarse en la Tabla 20 y en la Ilustración 35. Se puede observar que el fitness alcanzado tiene un valor de **98,18**, obtenido como resultado de la aplicación de la fórmula de la función de adaptación para un **75,45% de cobertura** utilizando un total de **58 antenas**.

Como ya se ha comentado de forma previa, y tal y como ocurre con el caso del algoritmo con las antenas como umbral, los resultados que se obtienen acerca del valor del fitness son muy bajos. Esto se debe a que la selección inicial de las antenas se realiza de forma aleatoria, y en este caso, se favorecen desde el inicio un conjunto de antenas que en primer lugar pueden no ser las mejores, y además, resultan ser muchas. Esto provoca que las hormigas no consigan disminuir el número de antenas empleadas y de este modo ofrecer resultados cuya solución se encuentra muy lejos de ser la óptima.

Aún así, y para tener todas las perspectivas de análisis de los distintos algoritmos, se muestra en el Gráfico 18, la evolución que ha tenido el algoritmo a lo largo de su ejecución, en el caso de la mejor solución encontrada. Esto permite observar cómo van trabajando las hormigas y las soluciones que van

generando a medida que se actualiza el valor de la feromona o probabilidad de selección de las localizaciones de las antenas.

En primer lugar, se aprecia como el porcentaje de cobertura a lo largo de las generaciones se mantiene más o menos constante. Las variaciones en este valor en las distintas soluciones generadas, se debe a que es casi imposible para el caso de la cobertura obtener exactamente un 75%, ya que la condición de búsqueda que guía a la hormiga implica que seleccione mas antenas hasta el momento en que se consiga un porcentaje mínimo. Sin embargo, normalmente al seleccionar una antena, si estamos cerca del valor buscado, se consigue algo más. Esto no ocurre, como se observó anteriormente, en el caso de las antenas como umbral, ya que se trabaja siempre con números enteros de antenas (no se puede elegir media antena).

Resulta relevante observar el comportamiento del número de antenas a lo largo de la ejecución del algoritmo. Se aprecia como de forma inicial se emplean menor número de antenas, pero a partir de la mitad de las generaciones, la rutina que sigue es de aumento. Se ha considerado que este hecho puede venir determinado porque al inicio, se produce una exploración más amplia de las antenas a emplear y se alcanzan situaciones más óptimas. Sin embargo, y debido a que la selección de las antenas que se han favorecido no resultaban ser las mejores, finalmente se necesita de un mayor número de ellas para conseguir la solución.

Esto, por supuesto, resulta contraproducente y contrario a lo que se esperaba en el comportamiento de este algoritmo, pero como en otras ocasiones, se considera que no funciona correctamente con este problema, ya que este último no requiere de un orden de selección para constituir la solución.

Por último, en cuanto al valor del fitness, se puede entender su comportamiento al observar los valores de porcentaje de cobertura y número de antenas. El fitness comienza aumentando de forma lenta y paulatina al inicio, cuando ocurre que el número de antenas empleadas también decrece mientras que el porcentaje de cobertura permanece siempre constante, para finalmente disminuir a medida que el número de antenas aumenta pero obteniendo el mismo porcentaje de cobertura.




Gráfico 18: Evolución de la mejor solución de RNDHormigas Original con Porcentaje de cobertura como umbral, mostrando los resultados de la mejor solución de cada población (Eje X: Población).

5.4 Resultados y Análisis del Algoritmo de Colonias de Hormigas con Clustering.

Por último, se realiza el análisis de los resultados obtenidos del Algoritmo de Colonias de Hormigas con Clustering.

Como ya se ha descrito con anterioridad en el apartado **“4.6 Descripción Algoritmo de Colonias de Hormigas con Clustering Desarrollado”**, se trata del mismo algoritmo de colonias de hormigas analizado de forma previa, el caso concreto en el que se escoge como solución un subconjunto de la generada por la hormiga, el cual proporciona el mayor valor de fitness de la misma. Además, en este algoritmo, se trabaja únicamente con la opción de la cobertura como umbral, ya que al establecer los cluster's para realizar agrupaciones de localizaciones de antenas por proximidad geográfica, e imponer que para crear la solución únicamente se puede seleccionar una antena de cada cluster, resulta innecesario tener la opción de establecer el nº de antenas como umbral.

Al tratar únicamente con la opción de la cobertura como umbral, se estableció que este sería el 100% de la cobertura, para asegurar de este modo, que la hormiga siempre buscará la solución con el mayor porcentaje posible de cobertura, y evitar así, la posibilidad de encontrar soluciones óptimas por limitar antes de tiempo la solución generada por la hormiga.

Al ofrecer al algoritmo de hormigas agrupaciones de antenas por proximidad geográfica en lugar de la totalidad de las 1.000 antenas, conseguimos de forma inicial asegurarnos que el solapamiento que generará la solución será prácticamente mínimo y del mismo modo, que no se seleccionarán antenas demasiado próximas entre sí que no favorecen el aumento del valor del fitness. Con esto se garantiza la obtención de mejores resultados que con el algoritmo de Colonias de Hormigas sin Cluster.

En el estudio de este algoritmo, se ha trabajado con dos métodos distintos de clustering cuyo análisis se realizará a continuación. Sin embargo, existe una serie de parámetros comunes a ambas opciones, como son el número de evaluaciones y los valores de las constantes de actualización de feromonas, que se estudiarán de forma global para ambas antes de realizar pruebas con distintos números de cluster para cada método.

En primer lugar, se realiza el estudio para determinar el número máximo de evaluaciones que realizará en su ejecución el algoritmo de Colonias de Hormigas con Clustering. Para ello, se decidió realizar pruebas con 100.000, 200.000 y 500.000 evaluaciones, estableciendo para el resto de parámetros valores elegidos al azar, que en este caso han sido el hecho de emplear el método de “SimpleKMeans” (K-Medias) con 50 cluster y valores para γ , α y β de 0.003, 0.002 y 0.002 respectivamente.

Individuos Evaluados	Tamaño Población	Algoritmo Clustering	Nº Cluster	GAMMA	ALFA	BETA	Evaluación Mejor	Fitness	Cobertura	Antenas
100000	500	K-Medias	50	0.003	0.002	0.002	27674	107,61	68,81%	44
200000	500	K-Medias	50	0.003	0.002	0.002	186841	112,38	67,04%	40
500000	500	K-Medias	50	0.003	0.002	0.002	494243	115,32	68,76%	41

Tabla 21: Resultados obtenidos para el estudio del n° máximo de evaluaciones para el algoritmo de Colonias de Hormigas con Clustering.

Los resultados obtenidos pueden observarse en la Tabla 21. Con estos datos, se puede determinar que a medida que aumentamos el número de evaluaciones, aumenta también el valor de fitness alcanzado, ya que se consigue mantener el porcentaje de cobertura, pero minimizando el número de antenas. Con esto, se determina que el conjunto de pruebas general para el estudio de este algoritmo, se realizará con 500.000 evaluaciones, ya que se consigue un mejor resultado. Se ha decidido, no aumentar el número de evaluaciones para este conjunto de pruebas, por el hecho del coste computacional que implica, y al estar trabajando con un periodo de tiempo limitado, no merece la pena emplear mucho más en obtener resultados para únicamente establecer la mejor configuración del algoritmo.

Sin embargo, se ha adoptado la resolución de emplear un valor de 1.000.000 evaluaciones para obtener los resultados del algoritmo una vez determinado los valores óptimos para todos los parámetros.

Con el número de evaluaciones a emplear establecido, se llevan a cabo un conjunto de pruebas, con el fin de determinar los valores de las constantes de actualización de feromona de las antenas más adecuados. Para estas pruebas, se imponen las 500.000 evaluaciones decididas anteriormente, empleando tal y como ocurrió con el estudio de

las evaluaciones el método SimpleKMeans con 50 clusters. Los valores de γ , α y β que se van a estudiar son los siguientes:

- a) 0.003, 0.002 y 0.002.
- b) 0.03, 0.02 y 0.02.
- c) 0.3, 0.2 y 0.2.
- d) 0.6, 0.3 y 0.3.
- e) 0.9, 0.6 y 0.6.

Individuos Evaluados	Tamaño Población	Algoritmo Clustering	Nº Cluster	GAMMA	ALFA	BETA	Evaluación Mejor	Fitness	Cobertura	Antenas
500000	500	KMeans	50	0.003	0.002	0.002	494243	115,32	68,76%	41
500000	500	KMeans	50	0.03	0.02	0.02	464368	120,19	71,05%	42
500000	500	KMeans	50	0.3	0.2	0.2	288577	122,61	69,15%	39
500000	500	KMeans	50	0.6	0.3	0.3	473589	124,46	68,77%	38
500000	500	KMeans	50	0.9	0.6	0.6	448485	120,38	69,39%	40

Tabla 22: Resultados obtenidos de las pruebas para el análisis de los valores de γ , α y β para el algoritmo de Colonias de Hormigas con Clustering.

Los resultados obtenidos a partir de estas pruebas, que pueden observarse en la Tabla 22, muestran que la mejor solución se obtiene con los valores de 0.6, 0.3 y 0.3 para γ , α y β respectivamente. Como se puede advertir, estos valores de γ , α y β considerados óptimos para este algoritmo, son bastante más elevados que para el caso del algoritmo de Colonias de Hormigas sin Clustering. Esta circunstancia, tiene su explicación en la diferencia del método de actualización de la feromona al utilizar clusters. Al emplear los clusters, las probabilidades no se dividen entre 1.000 antenas, si no que por un lado se divide entre los X clusters, y dentro de cada cluster, se vuelve a dividir el 100% de probabilidades entre el número de localizaciones de antenas que éste contenga. De este modo, al trabajar cada uno con probabilidades mucho más elevadas, también es necesario emplear valores de las constantes de actualización más altos, para que ejerzan algún efecto diferenciador a la hora de actualizar la probabilidad de selección de cada posible emplazamiento de antena.

Una vez que ya se dispone de la configuración general del algoritmo común a ambos métodos según el algoritmo de clustering, se procede a realizar las pruebas para el análisis de ambos métodos de Clustering y diferente número de cluster empleados.

Debido a que se estableció en la descripción funcional del algoritmo que a la hormiga únicamente se le permitiría seleccionar solamente una localización para la antena en cada cluster, se tomó la decisión de ejecutar el algoritmo con un número de cluster de entorno a 50 y 60, ya que se conoce que la solución óptima al problema RND debe emplear aproximadamente ese número de antenas. Atendiendo a esta razón, se resolvió analizar los resultados generados por el algoritmo empleando los métodos de SimpleKMeans y EM con 40, 50, 60 y 70 clusters. De este modo, no establecemos limitaciones, y observamos los resultados que se obtienen permitiendo emplear más o menos antenas.

En la Tabla 23 se muestran los resultados obtenidos de la ejecución del algoritmo de Colonias de Hormigas con Clustering empleando los parámetros determinados con anterioridad como los más adecuados:

- **Tamaño Población:** 500
- **Nº Máximo de Evaluaciones:** 500000
- **Constantes de actualización de Feromona:**
 - γ : 0.6
 - α : 0.3
 - β : 0.3

Individuos Evaluados	Tamaño Población	Algoritmo Clustering	Nº Cluster	GAMMA	ALFA	BETA	Evaluación Mejor	Fitness	Cobertura	Antenas
500000	500	KMeans	40	0.6	0.3	0.3	130158	120,12	63,9%	34
500000	500	KMeans	50	0.6	0.3	0.3	473589	124,46	68,77%	38
500000	500	KMeans	60	0.6	0.3	0.3	14842	124,86	74,96%	45
500000	500	KMeans	70	0.6	0.3	0.3	210022	123,82	76,28%	47
500000	500	EM	40	0.6	0.3	0.3	106487	122,54	66,42%	36
500000	500	EM	50	0.6	0.3	0.3	301758	134,18	73,26%	40
500000	500	EM	60	0.6	0.3	0.3	49509	124,62	76,53%	47

Individuos Evaluados	Tamaño Población	Algoritmo Clustering	Nº Cluster	GAMMA	ALFA	BETA	Evaluación Mejor	Fitness	Cobertura	Antenas
500000	500	EM	70	0.6	0.3	0.3	484975	125,43	75,13%	45

Tabla 23: Resultados pruebas del estudio de los métodos de Clustering y número de cluster para el algoritmo de Colonias de Hormigas con Clustering.

Se aprecia como el mejor resultado lo ofrece el algoritmo de Clustering EM con 40 clusters, obteniendo casi 10 puntos de diferencia con el resto en el valor del fitness. Esta configuración ha conseguido casi el mismo porcentaje de cobertura ofrecido por otras soluciones, pero minimizando notablemente el número de antenas empleadas, lo que provoca que el fitness crezca tanto.

Dejando al margen, de momento, esta configuración óptima del algoritmo, se pueden advertir otra serie de detalles acerca de los resultados ofrecidos por el algoritmo. En primer lugar, cabe destacar como en los 4 casos, el método de clustering EM iguala o supera en fitness a los resultados obtenidos por el método SimpleKMeans, por lo que se deduce que el uso del primero de éstos, es más adecuado para la resolución del problema RND con el algoritmo de Colonias de Hormigas.

Por otra parte, se puede observar como los porcentajes de cobertura que proporciona la solución adoptada por el algoritmo se comprenden siempre en un rango aproximado de 65 y 75% de cobertura. Los resultados de cobertura que ofrecen no son muy buenos, pero sin embargo son iguales o mayores que los alcanzados con el algoritmo de Colonias de Hormigas sin Clustering, pero utilizando un menor número de antenas, lo cual supone una mejora.

Por último, en cuanto al número de antenas empleadas, se observa que en ningún caso las soluciones encontradas emplean un número mayor de 50 antenas, ya se trabaje con un número mayor o menor de cluster, por lo que se puede concluir que el algoritmo funciona en este aspecto bastante bien, ya que se aproxima bastante a la solución óptima en cuanto al uso de antenas se refiere. El hecho de aumentar el número de clusters, atendiendo a los resultados obtenidos, únicamente ofrece al algoritmo el tratar con mayor número de agrupaciones entre las que elegir sin necesidad, ya que si con 50 cluster se obtienen los mejores resultados, y además siempre se emplean un número menor a 50 antenas, implica que al utilizar 70 clusters, los 20 restantes de la diferencia

con los 50, pueden agruparse dentro de los otros 50 y ofrecer una visión más real de la situación y la proximidad geográfica de las antenas.

Ya se conoce de entre las diferentes alternativas, que configuración ofrece mejores resultados. De este modo, y con esta configuración, se pretende estudiar un poco más el funcionamiento del algoritmo, desde el punto de vista de los valores reales que puede ofrecer, ejecutando un conjunto de pruebas con la misma configuración para obtener su media, y por otro lado, de la evolución que sigue el algoritmo de Colonias de Hormigas con Clustering para alcanzar la solución final.

Prueba	Individuos Evaluados	Tamaño Población	Algoritmo Clustering	Nº Cluster	GAMMA	ALFA	BETA	Evaluación Mejor	Fitness	Cobertura	Antenas
1	1000000	500	EM	50	0.6	0.3	0.3	725488	133,27	75,7%	43
2	1000000	500	EM	50	0.6	0.3	0.3	888317	133,33	74,83%	42
3	1000000	500	EM	50	0.6	0.3	0.3	969814	134,74	75,22%	42
4	1000000	500	EM	50	0.6	0.3	0.3	778036	134,73	73,41%	40
5	1000000	500	EM	50	0.6	0.3	0.3	553176	130,87	74,13%	42
6	1000000	500	EM	50	0.6	0.3	0.3	681892	133,16	73,89%	41
7	1000000	500	EM	50	0.6	0.3	0.3	422369	130,01	73,011%	41
8	1000000	500	EM	50	0.6	0.3	0.3	968169	134,73	76,11%	43
9	1000000	500	EM	50	0.6	0.3	0.3	233602	131,74	75,26%	43
10	1000000	500	EM	50	0.6	0.3	0.3	920417	126,4	71,98%	41

Tabla 24: Resultados del conjunto de 10 ejecuciones con la mejor configuración para el algoritmo de Colonias de Hormigas con Clustering.

Para lo primero, se han realizado un conjunto de 10 pruebas, cuyos resultados puede observarse en la Tabla 24. En los gráficos 19, 20 y 21 se muestran los resultados obtenidos para el número de antenas empleados, el porcentaje de cobertura obtenido y el valor del fitness alcanzado respectivamente, en cada una de las pruebas.




Gráfico 19: N° de Antenas Resultados Algoritmo de Colonias de Hormigas con Configuración Óptima.




Gráfico 20: Porcentaje de Cobertura Resultados Algoritmo de Colonias de Hormigas con Configuración Óptima.




Gráfico 21: Fitness Resultados Algoritmo de Colonias de Hormigas con Configuración Óptima.

Igualmente, se observa en los gráficos, como los valores de fitness obtenidos se mantienen en el rango [126,135]; el porcentaje de cobertura [71,76] y el número de antenas [40,43]. Estos rangos nos ofrecen una visión bastante positiva del algoritmo, ya que no se trata de que haya encontrado una buena solución por una determinada casualidad de una óptima selección inicial de las antenas, sino que los valores son homogéneos y su variación es muy pequeña, lo que implica que realmente esta configuración funciona bien siempre con este algoritmo para el escenario concreto que se está estudiando.

Con estos resultados, se han calculado los valores medios de fitness, porcentaje de cobertura y número de antenas obtenidos con la ejecución del algoritmo de Colonias de Hormigas con Clustering, con su configuración óptima. Estos valores son los siguientes, y que se pueden apreciar de forma visual en el gráfico de dispersión 22:

- **Fitness:** 132.
- **Porcentaje de Cobertura:** 74%.
- **Nº de Antenas:** 42.




Gráfico 22: Gráfico de Dispersión de las soluciones con la configuración óptima para el algoritmo de Colonias de Hormigas con Clustering.

De entre estas 10 pruebas, se ha obtenido que el mejor resultado para el algoritmo de Colonias de Hormigas con Clustering de entre todas las ejecuciones realizadas ofrece un **134,74 de fitness**, logrado a partir de la aplicación de la función de adaptación del problema RND con un **74,22% de cobertura** y **42 número de antenas**. La representación de esta solución puede encontrarse en la Ilustración 36 generada por la aplicación del proyecto.

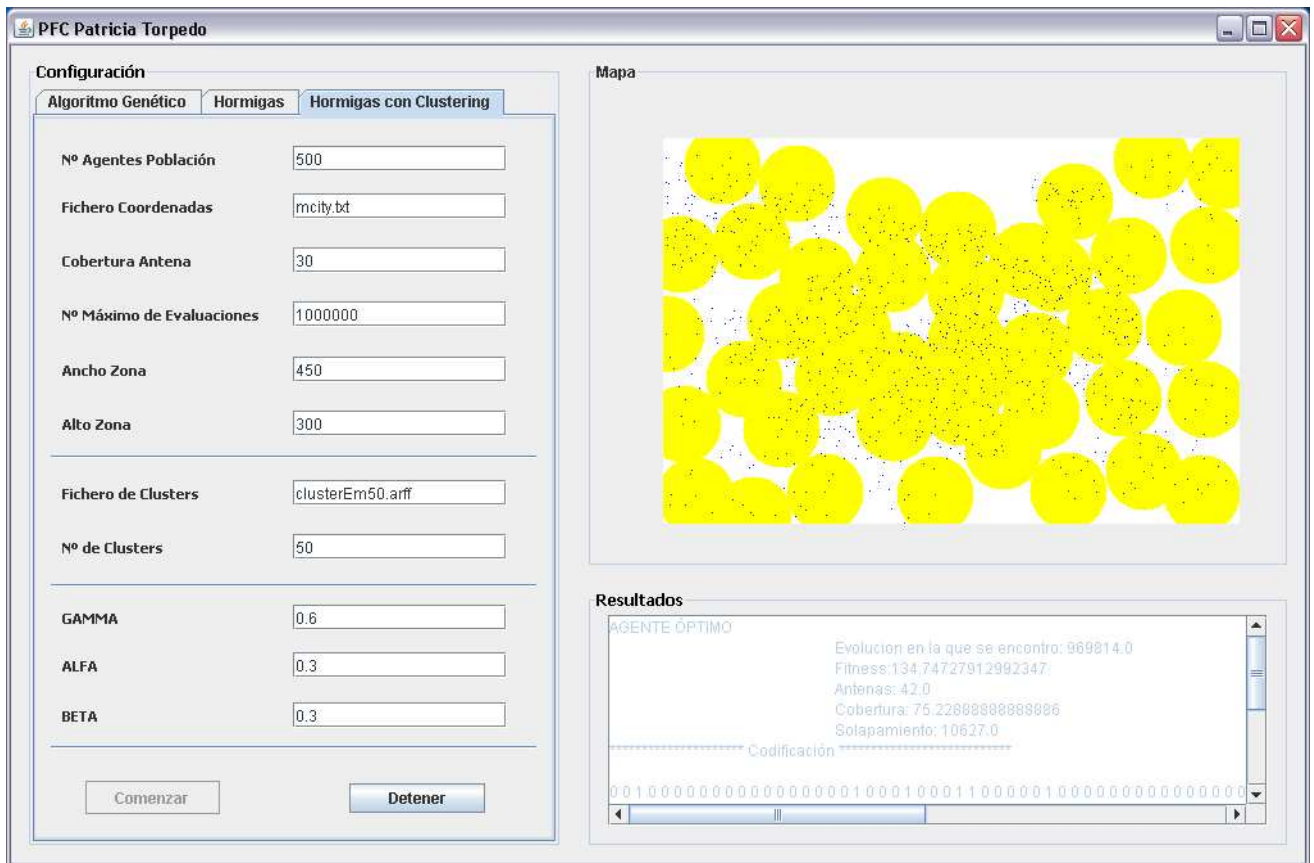


Ilustración 34: Mejor Resultado del Algoritmo de Colonias de Hormigas con Clustering.

Con esta solución al problema RND obtenida por el algoritmo de Colonias de Hormigas con Clustering, se muestra en el Gráfico 23, la evolución que han sufrido las soluciones a lo largo de la ejecución del algoritmo.

Se puede apreciar a simple vista, como para este algoritmo, el valor que se obtiene para el fitness va creciendo de forma paulatina al comienzo, para posteriormente mantenerse siempre en el mismo rango de valores. Esto ya supone un indicador que hace pensar que el hecho de introducir los cluster, provoca que el algoritmo funcione mejor, con menos coste computacional y que ofrezca mejores resultados.

Aun así, a lo largo de las ejecuciones se observa que el fitness no va siempre en incremento, si no que si se compara una población con la siguiente, la mejor solución que proporciona puede ser incluso menor. Sin embargo, y a diferencia de lo que ocurría con el algoritmo de Colonias de Hormigas sin Clustering, esta diferencia es mucho menor, permitiendo de este modo obtener mejoras cada menos evaluación, además de contar con un algoritmo que produce resultados mucho más estables.

En cuanto a la evolución del porcentaje de cobertura, señalar que se mantiene prácticamente constante a lo largo de todas las soluciones generadas en la ejecución del algoritmo, obteniendo siempre entre un 70 y un 80% de cobertura. Si tenemos en cuenta que la aplicación de clusters implica que no se pueda utilizar nunca un mayor número de antenas que de clusters se dispone, se entiende perfectamente que la evolución en el número de antenas permanezca siempre entorno al uso de 40 antenas, lo que provoca que el porcentaje de cobertura que se obtiene tampoco crezca demasiado de una generación a otra.




Gráfico 23: Representación gráfica de la evolución de la mejor solución del algoritmo de Colonias de Hormigas con Clustering.

Pero si algo resulta realmente llamativo al analizar los datos de evolución de este algoritmo, es el alto valor de fitness que se alcanza desde las primeras evaluaciones, siempre superiores a un valor de 100. Por un lado, este hecho puede resultar bastante favorecedor, ya que podemos pensar que si desde un inicio las hormigas consiguen valores relativamente adecuados, a lo largo de las evaluaciones, los resultados a obtener serán increíblemente altos. Sin embargo, al estudiar la evolución que siguen las soluciones que se van generando, esta situación no parece ocurrir nunca. Es cierto que se consigue aumentar el valor de fitness de la solución de forma considerable, sin embargo, no se alcanza ni mucho menos los resultados obtenidos por el AG. Podemos

pensar, que esto sucede por la forma de actualización de la feromona de las antenas, que llegados a un punto, las hormigas siempre acaban seleccionando las mismas y se quedan atrapadas en máximos locales.

Esto mismo, ocurría con los algoritmos de Colonias de Hormigas sin Clustering analizados de forma previa, aunque con la introducción de clusters se ha conseguido minimizar este efecto en parte, ya que los resultados que se han obtenido han sido mucho mejores, y la evolución seguida por el algoritmo, mucho más estable.

Capítulo 6

Conclusiones

Con el desarrollo de este proyecto se pretendía realizar un estudio de la resolución del problema “Radio Network Design (RND)” en un escenario concreto de la ciudad de Málaga (España), mediante el uso de algoritmos bioinspirados.

El objetivo de este problema se centra en diseñar una red de antenas repetidoras de telefonía que consiga cubrir el mayor porcentaje de terreno con cobertura, pero a su vez minimizando el número empleado de estas antenas. El escenario para el estudio, como ya se ha comentado, se sitúa en la ciudad de Málaga cuya representación para el problema se realiza con una matriz de 300 filas x 450 columnas. Para este entorno, se dispone de un total de 1.000 posibles localizaciones para situar las antenas, las cuales se caracterizan por generar una cobertura de radio circular de 30.

Para la resolución de este problema, se han desarrollado tres modelos de algoritmos bioinspirados:

- **Algoritmos Genético:** Se trata de un tipo de algoritmo evolutivo basado en poblaciones de individuos que se generan a raíz de la aplicación de métodos de selección, cruce y mutación.
- **Algoritmos de Colonias de Hormigas:** Se trata de un algoritmo evolutivo, basado en el comportamiento natural de las hormigas para la búsqueda y transporte del alimento desde su lugar de origen hasta el hormiguero.
- **Algoritmos de Colonias de Hormigas con Clustering:** Se trata del mismo algoritmo de Colonias de Hormigas, pero combinado con métodos de Clustering como el SimpleKMeans o EM.

Estos tres modelos de algoritmos bioinspirados y todas las versiones desarrolladas para cada uno de ellos, han sido probados, estudiados y analizados de forma previa en “Capítulo 5. Resultados y Análisis” del presente documento, y en base a toda la información obtenida, se procede a continuación, a realizar una serie de conclusiones de forma individual de cada uno de ellos y global al conjunto.

Los tres modelos de algoritmos desarrollados son técnicas de computación biológica, y como tal, gran parte de su buen funcionamiento recae en la codificación realizada para los individuos que manejan. A pesar de haber desarrollado la forma de codificación más sencilla posible para representar a cada uno de los individuos, no se ha podido evitar, debido al gran número de operaciones y cálculos que se ejecutan, el hecho de que las pruebas con entre 500.000 y 1.000.000 de evaluaciones, consumiesen tiempos de entre 12 y 48 horas en los peores casos. Este hecho, combinado con que, a priori es muy complicado establecer la mejor configuración para el algoritmo si no es basándose en la experiencia y pruebas generadas, ha provocado que obtener la mejor configuración posible para cada algoritmo, resultase muy costoso.

Por esta razón, se ha ejecutado un pequeño conjunto de pruebas, que sin resultar demasiado costoso en tiempo, permitiese obtener resultados adecuados para los algoritmos. Sin embargo, al encontrarnos en una situación limitada temporalmente, es posible que las configuraciones con las que se ha trabajado no sean las óptimas que se podrían alcanzar con un estudio más detallado.

A partir de esto, y teniendo en cuenta la situación en la que se está trabajando, se han alcanzado una serie de resultados y conclusiones referentes a los algoritmos estudiados.

El **Algoritmo Genético** que se ha desarrollado y analizado en este proyecto ha incluido una serie de modificaciones con respecto a la concepción original de éstos, que ha permitido obtener resultados más adecuados a la hora de resolver el problema. Se ha incluido un nuevo operador de selección, ajeno a los tradicionales de ruleta o torneo, al que se ha denominado Campeonato, con el cual se ha conseguido obtener los mejores resultados relativos al fitness, y no solamente eso, sino que además gracias a este método, se ha encontrado la solución óptima en un menor número de generaciones. Al mismo tiempo, también se ha incluido una nueva forma de ejecutar el operador de mutación, que igualmente favorece el decremento del tiempo de ejecución del algoritmo, basando su funcionamiento en establecer en primer lugar, el número de alelos del total de los individuos de la población que va a mutar, para después, seleccionar de forma aleatoria los individuos y alelos de éstos, que se va a someter a la mutación.

Todas estas modificaciones que han permitido encontrar mejores soluciones al problema RND, se deben a que los AG son un tipo de algoritmo evolutivo o

bioinspirado que gracias a su versatilidad es capaz de ofrecer buenos resultados en casi cualquier problema.

Los resultados ofrecidos por el **AG** con la mejor configuración encontrada para el mismo, son muy alentadores ya que producen unos valores **medios de 152 para el fitness con un 83% de cobertura empleando únicamente 46 antenas**. Si a esto le añadimos, que se ha encontrado una ejecución del algoritmo que ofrece como solución un **83,96% de cobertura con 45 antenas, generando un valor de fitness de 155,91**, estamos en una situación muy próxima al óptimo del problema, que con altas probabilidades podría alcanzarse incluyendo ligeras modificaciones y mejoras al algoritmo.

En el caso del **Algoritmo de Colonias de Hormigas**, se han desarrollado diversas versiones del mismo, ya que con este modelo de algoritmo bioinspirado se pretende estudiar el problema RND desde nuevas perspectivas. Este algoritmo, ha tenido que ser concebido casi en su totalidad de forma original para la resolución de este problema, ya que la idea original del algoritmo de Colonias de Hormigas es la de encontrar el camino óptimo, y el problema RND se basa en el diseño de una red, en la que realmente no es relevante que antena se sitúa primero.

Las versiones que se han generado para este algoritmo, han sido las de utilizar como umbral para que la hormiga se detenga en la búsqueda de la solución, el número de antenas o bien el porcentaje de cobertura. Además, se ha estudiado estas dos alternativas con dos opciones más, que son las de dejar que la solución inicial encontrada por la hormiga se constituya como la final, y por otro lado, el establecer como solución final de la hormiga el subconjunto de mayor fitness de la solución inicial.

De este modo, se han podido estudiar los resultados que se pueden obtener al establecer un porcentaje de cobertura o un número de antenas mínimo a alcanzar.

Para el caso de la **cobertura como umbral en la versión** en la que la hormiga elige como solución final el **subconjunto de mayor fitness de la solución inicial**, se han obtenido con la mejor configuración encontrada los siguientes valores de **media: 103 de fitness, 66% de cobertura y 42 antenas**. Estos valores mejoran un poco con respecto a la **solución con mejores resultados** que ofrece un **72,65% de cobertura utilizando 50 antenas**, que genera un valor de **fitness de 105,56**.

En el caso del **número de antenas como umbral** en la misma versión que el anterior, se han obtenido con la mejor configuración encontrada los siguientes valores de **media: 103 de fitness, 68% de cobertura y 46 antenas**. Al igual que en el caso anterior, estos resultados mejoran en pequeña medida con la **mejor** solución encontrada que proporciona un **76,005% de cobertura mediante el uso de 55 antenas**, obteniendo así un valor de **fitness de 105,034**.

Estudiando ahora los resultados de la versión del **algoritmo de Colonias de Hormigas Original**, donde no se selecciona el subconjunto de mayor fitness de la solución, se han obtenido para el caso de las **antenas como umbral**, unos valores de **106,34 de fitness, con un 65,22% de cobertura y 40 antenas**, como **mejor solución** al algoritmo.

En el caso del **porcentaje de cobertura como umbral** para esta misma versión del algoritmo, los valores obtenidos para la mejor solución han sido de un **75,46% de cobertura empleando 58 antenas**, proporcionando de este modo un valor de **fitness de 98,18**.

Como se puede apreciar, estos resultados son mucho menores que los que se habían obtenido con el Algoritmo Genético en su mejor configuración. Tras el análisis de los resultados y funcionamiento del algoritmo realizado en apartados anteriores, se han alcanzado una serie de conclusiones que explican estos resultados inferiores.

El primer motivo que se encuentra para estos resultados tan bajos, está relacionado de forma intrínseca al algoritmo de Colonias de Hormigas. Y es que podemos decir, que la adaptación de un algoritmo para encontrar el camino óptimo no funciona igual de bien cuando se pretende diseñar una red, en la que el orden de selección o visita de las posiciones no es relevante en ningún caso. Para el problema RND no se dispone de valores ni de distancia, ni de coste existentes entre una posición de antena y otra, lo que provoca que una vez seleccionada una posición donde establecer una antena, para seleccionar la siguiente se vuelve a realizar de forma general para todas, sin tener más probabilidades en ser seleccionadas unas que otras en base a la elegida en último lugar. Al ser así, en este algoritmo la probabilidad de selección de una antena se determina únicamente por su valor de feromona, que tan solo está relacionado con el solapamiento local de la antena en la solución, así como con el solapamiento global de dicha solución. Esta forma de actualización de feromona, provoca que no exista relación entre la

selección de una antena y otra, y por tanto se pierde una ventaja del algoritmo de Colonias de Hormigas a la hora de resolver el problema.

Por otro lado, el bajo valor de los resultados obtenidos, puede justificarse también por el hecho de que al trabajar con 1.000 localizaciones para las antenas, las probabilidades que se les asignan al principio de la ejecución del algoritmo de forma equiprobable son demasiado pequeñas, y una vez que las hormigas comienzan a seleccionar un conjunto de antenas, cuando se realiza la actualización en el valor de feromona de cada una de ellas, y a pesar de que las constantes de actualización sean muy bajas, provoca que rápidamente unas localizaciones de antenas destaquen sobre otras. Al actualizarlas, éstas aumentan su valor de feromona y el resto los disminuye aún más. Este suceso induce a que las hormigas a lo largo de la ejecución del algoritmo, se decante en mayor proporción siempre por el mismo conjunto de emplazamientos de antenas y se estanque en un máximo local.

Por este motivo, entre otras razones, se desarrolló el **Algoritmo de Colonias de Hormigas con Clustering**. Se trata de un algoritmo que coincide en funcionamiento con el algoritmo de Colonias de Hormigas con Cobertura como umbral y que establece como solución final el subconjunto de mayor fitness de la solución inicial, pero al que se han introducido la modificación de que a la hora de seleccionar una antena a colocar, tiene la restricción de poder elegir únicamente una posición de cada cluster.

Los resultados que se han obtenido con este algoritmo son mucho mejores que para el mismo algoritmo sin clusters, obteniendo unos **valores medios de 132 de fitness, con un 74% de cobertura y 42 antenas** con la mejor configuración paramétrica. Además, mejorando estos valores, se ha conseguido como **mejor solución** unos valores de un **75,22% de cobertura con 42 antenas generando así un valor de fitness de 134,74**.

Simplemente con estos datos, ya se puede apreciar como la aplicación de clusters en el algoritmo mejora notablemente los resultados que se pueden obtener con la ejecución del mismo para la resolución del problema RND. Se mejora el valor del fitness en 30 puntos, lo que supone una mejora significativa por el simple hecho de incluir agrupaciones de antenas y limitar la selección de estas a una por grupo.

Se considera que esta mejora se debe a que al restringir a una antena por agrupación, se limita las posibilidades de elección que tiene que realizar la hormiga, debido a que por ejemplo, la hormiga tendrá que elegir primero entre 50 clusters, en lugar de un total

de 1.000 antenas, para luego elegir entre las X posiciones de antenas que contenga ese cluster. Además, al realizarlo de este modo los valores de probabilidades se asignan de forma independiente para las posiciones de cada clusters; es decir, la suma de las probabilidades de las posiciones de antenas de cada cluster suman 100. Por esto, las probabilidades de selección de las antenas con las que se trabajan son más elevadas, y por tanto más manejables, lo que provoca que a la hora de realizar el proceso de actualización de feromona, las diferencias en los valores de probabilidad de selección se produzcan de forma paulatina, y no se encuentre que rápidamente unas antenas destaquen mucho más que otras.

Además, con estas agrupaciones se establece desde el inicio, que la hormiga en su búsqueda de la solución podrá emplear como mucho, tantas antenas como clusters se hayan definido para el algoritmo. Esto permite que, a partir del momento en el que las hormigas comienzan a identificar las posiciones de antenas más favorables, las soluciones que comienzan a obtenerse son aceptables, ya que se asegura cierta proporcionalidad entre porcentaje de cobertura y número de antenas empleadas que producen fitness relativamente elevados.

Por tanto, puede decirse que el uso de clusters en el algoritmo ha resultado muy positivo para la resolución de forma mejorada del problema RND. Ofrece conocimiento adicional y muy valioso al agrupar las posiciones de antenas en base a sus vecinas, permitiendo de este modo, minimizar el solapamiento de la solución final, y además consigue ofrecer una distribución uniforme de las antenas gracias a las agrupaciones de las posiciones que produce. Todas estas mejoras que ofrece la aplicación de clusters se ven incrementadas si se tiene en cuenta que el uso de los mismos no supone coste adicional al algoritmo.

Sin embargo, los resultados que se obtienen no son tan buenos como los obtenidos con los algoritmos genéticos. Por los estudios y análisis realizados sobre el funcionamiento de los algoritmos, se piensa que el problema fundamental reside en la base de funcionamiento del algoritmo de Colonias de Hormigas, que presenta menor versatilidad que el AG en el caso de estudio concreto que se está tratando, y que además su adaptación de algoritmo de búsqueda de camino óptimo a algoritmo de optimización en el diseño de redes no es tan adecuado como el AG desarrollado.

Se opina, que estas diferencias de resultados entre los algoritmos pueden deberse a que mientras que por un lado, en el algoritmo genético la generación de nuevos

individuos, siempre surge de la combinación de unos padres a partir de los cuales se puede sufrir ligeras mutaciones; en el caso del algoritmo de Colonias de Hormigas, cada hormiga de la población comienza a generar una solución desde 0, y aunque basando su elección en la probabilidad de selección de cada antena, la guía que sigue para generar soluciones es mucho menor que la que ofrece un AG.

A continuación, se procede a mostrar una serie de gráficos comparativos de los algoritmos estudiados respecto a la evolución del fitness, resultados de sus mejores soluciones, y los valores medios de cada uno obtenidos con la mejor configuración.




Gráfico 24: Gráfico comparativo de la evolución en el valor del fitness para la mejor solución de cada algoritmo bioinspirado estudiado.

Observando los gráficos 24, 25 y 26 que ofrecen comparativas en cuanto a los resultados obtenidos en las ejecuciones de los distintos algoritmos bioinspirados estudiados, se han alcanzado una serie de conclusiones globales entre ellos.

En primer lugar, y fijándonos en el gráfico 24 que nos muestra la evolución de los algoritmos en su mejor solución, se aprecia rápidamente como el caso del AG no sólo es el que mayor valor de fitness ofrece, sino que además es capaz de alcanzarlo con un coste computacional y temporal mucho menor, ya que requiere de menor número de evaluaciones.

Si además tenemos en cuenta el gráfico 25, donde podemos ver los valores de los mejores resultados de la solución de cada algoritmo, observamos así mismo, como la

solución del AG despunta notablemente frente al resto de algoritmos, tanto en valor de fitness como en porcentaje de cobertura.

Se aprecia como las cuatro versiones del algoritmo de Colonias de Hormigas ofrecen resultados muy similares, que no consiguen acercarse a la solución proporcionada por el AG. Únicamente, es el caso del algoritmo de Colonias de Hormigas con Clustering, el que ofrece unos resultados más alentadores, aproximándose algo más a la solución generada por el AG.




Gráfico 25: Gráfico de columnas comparativo sobre los mejores resultados para los Algoritmos Bioinspirados estudiados en función del Fitness, Porcentaje de Cobertura y N° de Antenas.

Por último, si se observa el gráfico comparativo sobre los valores medios (no se han incluido las versiones del algoritmo de Colonias de Hormigas Original, ya que no se han realizado diversas ejecuciones), las conclusiones a las que se puede llegar son las mismas. Aunque el AG baje su valor de fitness en media, éste continúa siendo muy superior al del resto, acercándose a él, solamente el caso del algoritmo de Colonias de Hormigas con Clustering, que a pesar de proporcionar un porcentaje de cobertura menor, también utiliza un considerable menor número de antenas, que depende de la situación en la que nos encontremos, puede resultar atractivo el empleo de este algoritmo, en sustitución del AG.




Gráfico 26: Gráfico de columnas comparativo sobre los valores medios para los Algoritmos con la configuración óptima de cada uno de ellos.

Concluyendo, y en base a los resultados y análisis de los mismos, cabe destacar el hecho de que entre los algoritmos desarrollados, el que ofrece una mejor solución al problema RND es el Algoritmo Genético.

La ejecución de este algoritmo para la resolución del problema que nos ocupa, ofrece valores del fitness muy elevados, consiguiendo además cubrir un altísimo porcentaje del territorio. Pero no es el simple hecho de que este algoritmo ofrezca mejores resultados lo que lo convierte en la mejor opción para la resolución de este problema, sino que además es capaz de encontrarla en un menor número de evaluaciones, lo que implica menor coste temporal y computacional para encontrar una solución al problema.

Todo esto, unido a su versatilidad para su adaptación a distintos escenarios, lo convierte en un candidato perfecto para resolver el problema RND.

Sin embargo, no hay que olvidar, que a pesar de que los resultados obtenidos con él no han sido los más óptimos, el algoritmo de Colonias de Hormigas en todas sus versiones, ofrece la posibilidad de estudiar y explorar las alternativas del problema RND que no se habían tenido en cuenta antes. Con estos algoritmos, e incluyendo algunas mejoras, se podrá analizar el problema RND para casos concretos en los que la situación no sea tan abierta, como conseguir un porcentaje de cobertura cualquiera con el menor número posible de antenas, sino en escenarios donde nos podamos encontrar

que a pesar de tener 1.000 posibles emplazamientos, por diversas razones, únicamente podamos hacer uso de un determinado número de antenas, o situaciones en las que se deba garantizar al menos un porcentaje mínimo de cobertura.

Resumiendo, en base a los resultados obtenidos en el estudio realizado, son los AG el modelo de algoritmo bioinspirado que mejores resultados proporciona a la hora de resolver el problema RND, de entre los distintos algoritmos estudiados.

Capítulo 7

Líneas Futuras

Todo el trabajo realizado en el presente proyecto, con sus estudios y análisis del problema, investigaciones y algoritmos desarrollados, puede servir como base para futuras líneas de investigación en la resolución del problema “*Radio Network Design (RND)*”, así como para problemas similares. En base a los algoritmos desarrollados, se proponen una serie de líneas futuras que podrían considerarse mejoras:

- Desarrollar un Algoritmo Genético con nichos, con lo que poder conseguir acelerar el proceso de búsqueda.
- Desarrollar un Algoritmo Genético con clustering, de modo que al igual que se consiguió con el algoritmo de Colonias de Hormigas, mejorar los resultados obtenidos al simplificar el proceso de elección de posiciones para las antenas, o experimentar con la “Hibridación de algoritmos”, para explotar complementariedades que pudiesen llegar a ofrecer mejores resultados. Por ejemplo, el uso conjunto de los algoritmos genéticos con búsquedas locales como OPT2.
- Al igual que se ideó el método de selección por Campeonato, desarrollar nuevos métodos de selección, cruce o mutación que favorezcan el funcionamiento del Algoritmo Genético.
- Realizar un conjunto de pruebas mayor, con mayor número de evaluaciones y estudio más detallado de los parámetros, a fin de determinar las posibilidades reales de los algoritmos generados, que por cuestiones de tiempo, ya que cada ejecución de los algoritmos podía tardar en los peores casos una media 24 horas, no se han podido contemplar en este proyecto.

Anexo I: Conjunto de Pruebas y Resultados Completo

1. Conjunto de pruebas total del Algoritmo Genético.

Prueba	Tamaño Población	Periodo Estancamiento	Tipo Fitness	Tipo Creación Población Inicial	Tipo Selección	Tipo Cruce	Max. Mutación	Min. Mutación	Cobertura	Antenas	Fitness
1	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	83,76%	45	155,91
2	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.4	0.15	82,58%	45	151,57
3	250	100	Por Cobertura	Limitada [50]	Campeonato	Uniforme	0.4	0.15	89,99%	73	110,95
4	500	100	Original	Limitada [50]	Torneo [4]	Uniforme	0.4	0.15	81,73%	45	148,47
5	500	200	Por Cobertura	Limitada [50]	Torneo [4]	Uniforme	0.2	0.05	87,93%	63	122,74
6	250	100	Original	Limitada [55]	Torneo [8]	Uniforme	0.4	0.15	81,86%	47	142,609
7	500	100	Por Cobertura	Limitada [50]	Torneo [8]	Uniforme	0.4	0.15	91,13%	95	87,42
8	500	100	Original	Original	Campeonato	Uniforme	0.4	0.15	87,63%	50	153,6
9	500	100	Por Cobertura	Original	Campeonato	Uniforme	0.4	0.15	95,44%	388	23,57
10	500	100	Original	Original	Torneo [4]	Uniforme	0.4	0.15	84,89%	48	150,15
11	500	500	Original	Original	Campeonato	Simple	0.4	0.15	25,46%	13	49,87
12	500	500	Original	Limitada [50]	Torneo [20]	Uniforme	0.4	0.15	84,78%	50	143,76
13	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	83,24%	46	150,63
14	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	84,52%	47	152,026
15	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	86,46%	49	152,56
16	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	81,43%	44	150,707
17	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	83,76%	45	155,91
18	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	82,54%	45	151,41
19	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	84,59%	47	152,25
20	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	82,66%	45	151,85
21	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	83,84%	47	149,57
22	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	85,72%	48	153,086
23	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	84,39%	47	151,56
24	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	80,72%	43	151,55
25	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	83,55%	46	151,76
26	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	85,06%	48	150,74
27	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	81,95%	44	152,64
28	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	84,9%	47	153,39
29	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	84,73%	48	149,58
30	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	83,5%	46	151,58
31	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	82,22%	45	150,25
32	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	85,53%	48	152,42
33	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	84,96%	47	153,608
34	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	85,45%	47	155,37

Prueba	Tamaño Población	Periodo Estancamiento	Tipo Fitness	Tipo Creación Población Inicial	Tipo Selección	Tipo Cruce	Max. Mutación	Min. Mutación	Cobertura	Antenas	Fitness
35	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	82,37%	45	150,78
36	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	83,35%	45	154,4
37	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	84,54%	47	152,096
38	500	100	Original	Original	Torneo[8]	Uniforme	0.2	0.05	83,305%	47	147,65
39	500	100	Original	Original	Campeonato	Uniforme	0.2	0.05	86,46%	51	146,57
40	500	100	Original	Limitada [50]	Torneo[8]	Uniforme	0.2	0.05	84,53%	48	148,89
41	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	83,55%	47	148,55
42	500	100	Original	Limitada [50]	Campeonato	Simple	0.2	0.05	66,32%	50	87,98
43	500	100	Original	Limitada [50]	Campeonato	Simple	0.2	0.05	65,27%	50	85,21
44	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	82,69%	45	151,94
45	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	83,99%	47	148,55
46	500	100	Original	Limitada [50]	Torneo[4]	Uniforme	0.2	0.05	81,81%	45	148,74
47	500	100	Original	Limitada [50]	Torneo[8]	Uniforme	0.2	0.05	85,89%	49	150,34
48	500	100	Original	Limitada [50]	Torneo[16]	Uniforme	0.2	0.05	85,08%	50	144,8
49	500	100	Original	Limitada [50]	Torneo[24]	Uniforme	0.2	0.05	82,12%	46	146,63
50	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	84,181%	47	150,77
51	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.5	0.3	86,051%	55	134,63
52	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.005	82,42%	45	150,97
53	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.1	0.0005	82,63%	46	148,46
54	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.2	0.05	86,33%	46	151,08
55	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.4	0.15	83,92%	48	146,33
56	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.4	0.2	80,71%	44	148,076
57	500	100	Original	Limitada [50]	Campeonato	Uniforme	0.4	0.15	82,58%	45	151,57
58	250	100	Por Cobertura	Limitada [50]	Campeonato	Uniforme	0.4	0.15	89,99%	73	110,95
59	500	100	Original	Limitada [50]	Torneo [4]	Uniforme	0.4	0.15	81,73%	45	148,47
60	500	200	Por Cobertura	Limitada [50]	Torneo [4]	Uniforme	0.2	0.05	87,93%	63	122,74
61	250	100	Original	Limitada [55]	Torneo [8]	Uniforme	0.4	0.15	81,86%	47	142,609
62	500	100	Por Cobertura	Limitada [50]	Torneo [8]	Uniforme	0.4	0.15	91,13%	95	87,42
63	500	100	Original	Original	Campeonato	Uniforme	0.4	0.15	87,63%	50	153,6
64	500	100	Por Cobertura	Original	Campeonato	Uniforme	0.4	0.15	95,44%	388	23,57

Tabla 25: Conjunto total de pruebas realizadas para el AG.

2. Conjunto de pruebas total del Algoritmo de Colonias de Hormigas Modificado.

Prueba	Individuos Evaluados	Tamaño Población	Tipo	Umbral	GAMMA	ALFA	BETA	Evaluación Mejor	Fitness	Cobertura	Antenas
1	500000	500	Antenas	55	0.9	0.6	0.6	215	90,37	57,03%	36
2	300000	500	Antenas	45	0.6	0.4	0.4	1439	92,19	59,19%	38
3	100000	500	Antenas	40	0.003	0.002	0.002	3698	95,94	61,95%	40
4	200000	500	Antenas	40	0.003	0.002	0.002	694	96,29	62,062%	40
5	500000	500	Antenas	40	0.003	0.002	0.002	2528	97,61	62,48%	40
6	500000	500	Antenas	40	0.03	0.02	0.02	1062	94,81	58,42%	36
7	500000	500	Antenas	40	0.3	0.2	0.2	988	95,54	57,82%	35
8	500000	500	Antenas	40	0.6	0.3	0.3	204	88,54	59,51%	40
9	500000	500	Antenas	40	0.9	0.6	0.6	199	84,92	57,55%	39
10	500000	500	Antenas	40	0.00003	0.00003	0.00003	171942	102,35	59,85%	35
11	100000	500	Antenas	50	0.003	0.002	0.002	2667	96,47	65,88%	45
12	200000	500	Antenas	50	0.003	0.002	0.002	2992	95,81	68,51%	49
13	500000	500	Antenas	50	0.003	0.002	0.002	2764	95,7	61,87%	40
14	500000	500	Antenas	50	0.03	0.02	0.02	1494	94,15	59,02%	37
15	500000	500	Antenas	50	0.3	0.2	0.2	179	95,35	57,76%	35
16	500000	500	Antenas	50	0.6	0.3	0.3	278	83,58	63,34%	48
17	500000	500	Antenas	50	0.9	0.6	0.6	531	91,89	63,58%	44
18	500000	500	Antenas	50	0.00003	0.00003	0.00003	153715	102,72	67,23%	44
19	100000	500	Antenas	60	0.003	0.002	0.002	2456	100,68	69,51%	48
20	200000	500	Antenas	60	0.003	0.002	0.002	2061	99,66	67,71%	46
21	500000	500	Antenas	60	0.003	0.002	0.002	1744	99,006	74,77%	58
22	500000	500	Antenas	60	0.03	0.02	0.02	729	97,59	65,53%	44
23	500000	500	Antenas	60	0.3	0.2	0.2	655	85,47	62,01%	45
24	500000	500	Antenas	60	0.6	0.3	0.3	753	86,74	64,52%	49
25	500000	500	Antenas	60	0.9	0.6	0.6	486	92,06	61,43%	41
26	500000	500	Antenas	60	0.00003	0.00003	0.00003	166621	103,702	65,99%	42
27	100000	500	Cobertura	75	0.003	0.002	0.002	962	98,61	62,01%	39
28	200000	500	Cobertura	75	0.003	0.002	0.002	3446	100,09	66,36%	44
29	500000	500	Cobertura	75	0.003	0.002	0.002	3332	97,88	63,34%	41
30	500000	500	Cobertura	75	0.03	0.02	0.02	2136	96,39	57,24%	34
31	500000	500	Cobertura	75	0.3	0.2	0.2	1329	90,31	64,45%	46
32	500000	500	Cobertura	75	0.6	0.3	0.3	838	90,52	71,2%	56
33	500000	500	Cobertura	75	0.9	0.6	0.6	1404	92,65	55,29%	33
34	500000	500	Cobertura	75	0.00003	0.00003	0.00003	94364	101,47	68,32%	46
35	100000	500	Cobertura	85	0.003	0.002	0.002	2793	95,03	61,65%	40
36	200000	500	Cobertura	85	0.003	0.002	0.002	1970	95,43	64,05%	43
37	500000	500	Cobertura	85	0.003	0.002	0.002	7838	99,91	67,05%	45
38	500000	500	Cobertura	85	0.03	0.02	0.02	658	93,61	56,41%	34
39	500000	500	Cobertura	85	0.3	0.2	0.2	696	89,04	69,34%	54
40	500000	500	Cobertura	85	0.6	0.3	0.3	51	88,16	70,88%	57
41	500000	500	Cobertura	85	0.9	0.6	0.6	314	88,25	64,4%	47
42	500000	500	Cobertura	85	0.00003	0.00003	0.00003	122300	104,39	65,42%	41
43	100000	500	Cobertura	90	0.003	0.002	0.002	2396	98,51	72,93%	54
44	200000	500	Cobertura	90	0.003	0.002	0.002	2338	95,14	69,65%	51
45	500000	500	Cobertura	90	0.003	0.002	0.002	3366	99,64	68,43%	47
46	500000	500	Cobertura	90	0.03	0.02	0.02	852	98,6	68,07%	47

Prueba	Individuos Evaluados	Tamaño Población	Tipo	Umbral	GAMMA	ALFA	BETA	Evaluación Mejor	Fitness	Cobertura	Antenas
47	500000	500	Cobertura	90	0.3	0.2	0.2	583	90,66	62,43%	43
48	500000	500	Cobertura	90	0.6	0.3	0.3	614	90,64	61,7%	42
49	500000	500	Cobertura	90	0.9	0.6	0.6	456	86,57	65,79%	50
50	500000	500	Cobertura	90	0.00003	0.00003	0.00003	135705	104,55	63,03%	38
51	1000000	500	Antenas	60	0.00003	0.00002	0.00002	120710	103,31	71,87%	50
52	1000000	500	Antenas	60	0.00003	0.00002	0.00002	204039	102,83	57,36%	32
53	1000000	500	Antenas	60	0.00003	0.00002	0.00002	149681	103,14	63,42%	39
54	1000000	500	Antenas	60	0.00003	0.00002	0.00002	140668	101,51	74,03%	54
55	1000000	500	Antenas	60	0.00003	0.00002	0.00002	186651	104,66	68,62%	45
56	1000000	500	Antenas	60	0.00003	0.00002	0.00002	123960	101,73	66,14%	43
57	1000000	500	Antenas	60	0.00003	0.00002	0.00002	173271	102,13	64,71%	41
58	1000000	500	Antenas	60	0.00003	0.00002	0.00002	121784	105,034	76,005%	55
59	1000000	500	Antenas	60	0.00003	0.00002	0.00002	152386	102,1	72,16%	51
60	1000000	500	Antenas	60	0.00003	0.00002	0.00002	197378	104,056	69,18%	46
61	1000000	500	Cobertura	90	0.00003	0.00002	0.00002	86712	104,25	61,26%	36
62	1000000	500	Cobertura	90	0.00003	0.00002	0.00002	188480	103,55	70,5%	48
63	1000000	500	Cobertura	90	0.00003	0.00002	0.00002	138615	103,3	62,65%	38
64	1000000	500	Cobertura	90	0.00003	0.00002	0.00002	286101	101,03	59,46%	35
65	1000000	500	Cobertura	90	0.00003	0.00002	0.00002	144096	105,56	72,65%	50
66	1000000	500	Cobertura	90	0.00003	0.00002	0.00002	41474	105,37	68,09%	44
67	1000000	500	Cobertura	90	0.00003	0.00002	0.00002	132348	103,4	68,96%	46
68	1000000	500	Cobertura	90	0.00003	0.00002	0.00002	144153	101,63	59,64%	35
69	1000000	500	Cobertura	90	0.00003	0.00002	0.00002	146524	101,71	68,4%	46
70	1000000	500	Cobertura	90	0.00003	0.00002	0.00002	159412	105,32	70,35%	47

Tabla 26: Conjunto total de pruebas realizadas para el Algoritmo de Colonias de Hormigas Modificado.

3. Conjunto de pruebas total del Algoritmo de Colonias de Hormigas Original.

Prueba	Individuos Evaluados	Tamaño Población	Tipo	Umbral	GAMMA	ALFA	BETA	Evaluación Mejor	Fitness	Cobertura	Antenas
1	1000000	500	Antenas	40	0.0000000003	0.0000000002	0.0000000002	30642	98,22	62,68%	40
2	1000000	500	Antenas	45	0.0000000003	0.0000000002	0.0000000002	888969	97,67	66,29%	45
3	1000000	500	Antenas	50	0.0000000003	0.0000000002	0.0000000002	141923	95,32	69,037%	50
4	1000000	500	Antenas	55	0.0000000003	0.0000000002	0.0000000002	396293	94,43	72,06%	55
5	1000000	500	Antenas	60	0.0000000003	0.0000000002	0.0000000002	124460	92,02	74,3%	60
6	1000000	500	Antenas	65	0.0000000003	0.0000000002	0.0000000002	359368	94,91	78,54%	65
7	1000000	500	Antenas	70	0.0000000003	0.0000000002	0.0000000002	193514	88,78	78,83%	70
8	1000000	500	Antenas	40	0.0000000003	0.0000000002	0.0000000002	997970	95,84	61,91%	40
9	1000000	500	Antenas	45	0.0000000003	0.0000000002	0.0000000002	275888	96,14	65,77%	45
10	1000000	500	Antenas	50	0.0000000003	0.0000000002	0.0000000002	266159	94,1	68,59%	50
11	1000000	500	Antenas	55	0.0000000003	0.0000000002	0.0000000002	187957	92,72	71,41%	55
12	1000000	500	Antenas	60	0.0000000003	0.0000000002	0.0000000002	171210	93,85	75,04%	60
13	1000000	500	Antenas	65	0.0000000003	0.0000000002	0.0000000002	732466	90,8	76,82%	65
14	1000000	500	Antenas	70	0.0000000003	0.0000000002	0.0000000002	614013	86,94	78,01%	70
15	1000000	500	Antenas	40	0.0000000003	0.0000000002	0.0000000002	258140	96,66	62,18%	40
16	1000000	500	Antenas	45	0.0000000003	0.0000000002	0.0000000002	989459	101,61	67,62%	45
17	1000000	500	Antenas	50	0.0000000003	0.0000000002	0.0000000002	77461	95,35	69,04%	50
18	1000000	500	Antenas	55	0.0000000003	0.0000000002	0.0000000002	571704	94,37	72,04%	55
19	1000000	500	Antenas	60	0.0000000003	0.0000000002	0.0000000002	85971	90,72	73,78%	60
20	1000000	500	Antenas	65	0.0000000003	0.0000000002	0.0000000002	344882	89,19	76,14%	65
21	1000000	500	Antenas	70	0.0000000003	0.0000000002	0.0000000002	606502	87,86	78,42%	70
22	1000000	500	Antenas	40	0.0000000003	0.0000000002	0.0000000002	92576	99,65	63,13%	40
23	1000000	500	Antenas	45	0.0000000003	0.0000000002	0.0000000002	386463	97,46	66,22%	45
24	1000000	500	Antenas	50	0.0000000003	0.0000000002	0.0000000002	160153	94,88	68,87%	50
25	1000000	500	Antenas	55	0.0000000003	0.0000000002	0.0000000002	891771	92,31	71,25%	55
26	1000000	500	Antenas	60	0.0000000003	0.0000000002	0.0000000002	520007	90,47	73,67%	60
27	1000000	500	Antenas	65	0.0000000003	0.0000000002	0.0000000002	579146	90,76	76,8%	65
28	1000000	500	Antenas	70	0.0000000003	0.0000000002	0.0000000002	248229	88,36	78,64%	70
29	1000000	500	Antenas	40	0.0000000003	0.0000000002	0.0000000002	850664	102,12	63,91%	40
30	1000000	500	Antenas	45	0.0000000003	0.0000000002	0.0000000002	872113	98,84	66,69%	45
31	1000000	500	Antenas	50	0.0000000003	0.0000000002	0.0000000002	799418	98,81	70,29%	50
32	1000000	500	Antenas	55	0.0000000003	0.0000000002	0.0000000002	511584	101,13	74,58%	55
33	1000000	500	Antenas	60	0.0000000003	0.0000000002	0.0000000002	899895	96,96	76,27%	60
34	1000000	500	Antenas	65	0.0000000003	0.0000000002	0.0000000002	760061	92,61	77,58%	65
35	1000000	500	Antenas	70	0.0000000003	0.0000000002	0.0000000002	124756	93,35	80,83%	70
36	1000000	500	Antenas	40	0.0000000003	0.0000000002	0.0000000002	177431	106,34	65,22%	40
37	1000000	500	Antenas	45	0.0000000003	0.0000000002	0.0000000002	222125	103,06	68,1%	45
38	1000000	500	Antenas	50	0.0000000003	0.0000000002	0.0000000002	175112	101,32	71,17%	50
39	1000000	500	Antenas	55	0.0000000003	0.0000000002	0.0000000002	205253	100,16	74,22%	55
40	1000000	500	Antenas	60	0.0000000003	0.0000000002	0.0000000002	164364	95,77	75,8%	60
41	1000000	500	Antenas	65	0.0000000003	0.0000000002	0.0000000002	99447	94,93	78,55%	65
42	1000000	500	Antenas	40	0.0000000003	0.0000000002	0.0000000002	19614	98,11	62,64%	40
43	1000000	500	Antenas	45	0.0000000003	0.0000000002	0.0000000002	18282	100,29	67,17%	45
44	1000000	500	Antenas	50	0.0000000003	0.0000000002	0.0000000002	18203	95,26	69,01%	50
45	1000000	500	Cobertura	82	0.0000000003	0.0000000002	0.0000000002	985579	80,91	82,44%	84
46	1000000	500	Cobertura	60	0.0000000003	0.0000000002	0.0000000002	89439	91,36	74,03%	60

Prueba	Individuos Evaluados	Tamaño Población	Tipo	Umbral	GAMMA	ALFA	BETA	Evaluación Mejor	Fitness	Cobertura	Antenas
47	1000000	500	Cobertura	85	0.000000003	0.000000002	0.000000002	31556	71,56	85,01%	101
48	1000000	500	Cobertura	80	0.000000003	0.000000002	0.000000002	344490	82,2	80,07%	78
49	1000000	500	Cobertura	69	0.000000003	0.000000002	0.000000002	89439	91,36	74,03%	60
50	1000000	500	Cobertura	75	0.000000003	0.000000002	0.000000002	114912	89,65	75,75%	64
51	1000000	500	Cobertura	80	0.0000003	0.0000002	0.0000002	72745	82,64	81,31%	80
52	1000000	500	Cobertura	80	0.0000003	0.0000002	0.0000002	2422	84,61	80,18%	76
53	1000000	500	Cobertura	70	0.000003	0.000002	0.000002	949691	99,01	70,36%	50
54	1000000	500	Cobertura	75	0.000003	0.000002	0.000002	399642	95,89	75,21%	59
55	1000000	500	Cobertura	75	0.00003	0.00002	0.00002	286043	98,18	75,46%	58
56	1000000	500	Cobertura	85	0.00003	0.00002	0.00002	986294	88,86	85,88%	83
57	1000000	500	Cobertura	90	0.00003	0.00002	0.00002	959171	69,98	90,104%	116

Tabla 27: Conjunto total de pruebas realizadas para el Algoritmo de Colonias de Hormigas Original.

4. Conjunto de pruebas total del Algoritmo de Colonias de Hormigas con Clustering.

Prueba	Individuos Evaluados	Tamaño Población	Algoritmo Clustering	Nº Cluster	GAMMA	ALFA	BETA	Evaluación Mejor	Fitness	Cobertura	Antenas
1	200000	500	KMeans	60	0.9	0.6	0.6	161860	119,48	69,99%	41
2	100000	250	KMeans	60	0.4	0.2	0.2	57818	121,21	72,19%	43
3	300000	500	KMeans	50	0.6	0.4	0.4	144703	120,59	70,31%	41
4	100000	500	KMeans	40	0.003	0.002	0.002	61841	110,25	63,001%	36
5	200000	500	KMeans	40	0.003	0.002	0.002	190587	110,49	63,07%	36
6	500000	500	KMeans	40	0.003	0.002	0.002	449276	113,68	63,97%	36
7	500000	500	KMeans	40	0.03	0.02	0.02	259934	114,71	65,14%	37
8	500000	500	KMeans	40	0.3	0.2	0.2	159843	121,01	65,08%	35
9	500000	500	KMeans	40	0.6	0.3	0.3	130158	120,12	63,9%	34
10	500000	500	KMeans	40	0.9	0.6	0.6	388071	116,22	62,86%	34
11	100000	500	KMeans	50	0.003	0.002	0.002	27674	107,61	68,81%	44
12	200000	500	KMeans	50	0.003	0.002	0.002	186841	112,38	67,04%	40
13	500000	500	KMeans	50	0.003	0.002	0.002	494243	115,32	68,76%	41
14	500000	500	KMeans	50	0.03	0.02	0.02	464368	120,19	71,05%	42
15	500000	500	KMeans	50	0.3	0.2	0.2	288577	122,61	69,15%	39
16	500000	500	KMeans	50	0.6	0.3	0.3	473589	124,46	68,77%	38
17	500000	500	KMeans	50	0.9	0.6	0.6	448485	120,38	69,39%	40
18	100000	500	KMeans	60	0.003	0.002	0.002	73048	109,86	64,61%	38
19	200000	500	KMeans	60	0.003	0.002	0.002	49679	115,37	68,77%	41
20	500000	500	KMeans	60	0.003	0.002	0.002	440968	114,25	72,49%	46
21	500000	500	KMeans	60	0.03	0.02	0.02	499019	118,35	72,16%	44
22	500000	500	KMeans	60	0.3	0.2	0.2	341254	121,19	73,02%	44
23	500000	500	KMeans	60	0.6	0.3	0.3	14842	124,86	74,96%	45
24	500000	500	KMeans	60	0.9	0.6	0.6	318458	122,92	76,01%	47
25	100000	500	KMeans	70	0.003	0.002	0.002	21251	116,54	76,33%	50
26	200000	500	KMeans	70	0.003	0.002	0.002	91662	109,93	67,13%	41
27	500000	500	KMeans	70	0.003	0.002	0.002	413350	113,14	74,45%	49
28	500000	500	KMeans	70	0.03	0.02	0.02	3215	103,15	61,77%	37
29	500000	500	KMeans	70	0.3	0.2	0.2	434360	118,43	74,6%	47
30	500000	500	KMeans	70	0.6	0.3	0.3	210022	123,82	76,28%	47
31	500000	500	KMeans	70	0.9	0.6	0.6	70789	125,27	72,53%	42
32	100000	500	EM	40	0.003	0.002	0.002	74529	115,41	65,34%	37
33	200000	500	EM	40	0.003	0.002	0.002	188331	120,57	68,57%	39
34	500000	500	EM	40	0.003	0.002	0.002	414793	121,23	67,87%	38
35	500000	500	EM	40	0.03	0.02	0.02	202533	122,53	64,54%	34
36	500000	500	EM	40	0.3	0.2	0.2	9331	120,13	66,66%	37
37	500000	500	EM	40	0.6	0.3	0.3	106487	122,54	66,42%	36
38	500000	500	EM	40	0.9	0.6	0.6	211174	123,98	65,87%	35
39	100000	500	EM	50	0.003	0.002	0.002	92300	121,65	68,88%	39
40	200000	500	EM	50	0.003	0.002	0.002	138567	123,35	71,11%	41
41	500000	500	EM	50	0.003	0.002	0.002	375905	124,78	74,09%	44
42	500000	500	EM	50	0.03	0.02	0.02	445411	128,45	74,31%	44
43	500000	500	EM	50	0.3	0.2	0.2	141560	130,22	73,07%	41
44	500000	500	EM	50	0.6	0.3	0.3	301758	134,18	73,26%	40
45	500000	500	EM	50	0.9	0.6	0.6	470400	131,91	73,54%	41
46	100000	500	EM	60	0.003	0.002	0.002	66629	115,58	70,49%	43

Prueba	Individuos Evaluados	Tamaño Población	Algoritmo Clustering	Nº Cluster	GAMMA	ALFA	BETA	Evaluación Mejor	Fitness	Cobertura	Antenas
47	200000	500	EM	60	0.003	0.002	0.002	157982	117,29	68,49%	40
48	500000	500	EM	60	0.003	0.002	0.002	292503	125,69	76,03%	46
49	500000	500	EM	60	0.03	0.02	0.02	483565	120,04	73,49%	45
50	500000	500	EM	60	0.3	0.2	0.2	386073	120,13	75,14%	47
51	500000	500	EM	60	0.6	0.3	0.3	49509	124,62	76,53%	47
52	500000	500	EM	60	0.9	0.6	0.6	148987	129,18	78,74%	48
53	100000	500	EM	70	0.003	0.002	0.002	78041	112,44	70,33%	44
54	200000	500	EM	70	0.003	0.002	0.002	188228	115,12	72,77%	46
55	500000	500	EM	70	0.003	0.002	0.002	355919	117,93	73,65%	46
56	500000	500	EM	70	0.03	0.02	0.02	480871	122,55	72,59%	43
57	500000	500	EM	70	0.3	0.2	0.2	298535	124,05	76,35%	47
58	500000	500	EM	70	0.6	0.3	0.3	484975	125,43	75,13%	45
59	500000	500	EM	70	0.9	0.6	0.6	462802	124,58	74,03%	44
60	1000000	500	EM	50	0.6	0.3	0.3	725488	133,27	75,7%	43
61	1000000	500	EM	50	0.6	0.3	0.3	888317	133,33	74,83%	42
62	1000000	500	EM	50	0.6	0.3	0.3	969814	134,74	75,22%	42
63	1000000	500	EM	50	0.6	0.3	0.3	778036	134,73	73,41%	40
64	1000000	500	EM	50	0.6	0.3	0.3	553176	130,87	74,13%	42
65	1000000	500	EM	50	0.6	0.3	0.3	681892	133,16	73,89%	41
66	1000000	500	EM	50	0.6	0.3	0.3	422369	130,01	73,011%	41
67	1000000	500	EM	50	0.6	0.3	0.3	968169	134,73	76,11%	43
68	1000000	500	EM	50	0.6	0.3	0.3	233602	131,74	75,26%	43
69	1000000	500	EM	50	0.6	0.3	0.3	920417	126,4	71,98%	41

Tabla 28: Conjunto total de pruebas realizadas para el Algoritmo de Colonias de Hormigas con Clustering.

Bibliografía

[1] Y. Sáez and P. Isasi. Radio Design Networks: an evolutionary computation approach. 2008. Conferencia Internacional IEEE sobre Sistemas Híbridos Inteligentes, pp. 951-954.

[2] K. Tutschku. Demand-based radio network planning of cellular mobile communication systems. 1997. INFOCOM 98, vol. 3, pp. 1054-1061.

[3] Th. Fritsch, K. Tutschku and K. Leibenitz. Field strength prediction by ray-tracing for adaptive base station positioning in mobile communication networks. 1995. En las actas de la 2^a Conferencia de ITG de Comunicaciones Móviles '95, Neu Ulm VDE.

[4] K. Tutschku and K. Leibenitz. Fast Ray-Tracing for Field Strength Prediction in Cellular Mobile Network Planning. 1996. En las actas de la 46^a Conferencia del IEEE/VTs sobre Tecnología Vehicular, Atlanta IEEE.

[5] P. Tran-Gia, K. Tutschku and K. Leibenitz. ICEPT – An Integrated Cellular Network Planning Tool. 1997. En las actas de la 47^a Conferencia del IEEE/VTs sobre Tecnología Vehicular, Phoenix.

[6] P. Tran-Gia, K. Tutschku and N. Gerlich. An Integrated Approach To Cellular Network Planning. 1996. En las actas del 7^o Simposio Internacional sobre la Planificación de Redes. (Networks 96)

[7] H. Meunier, E. Talbi and P. Reininger. A Multiobjective Genetic Algorithm for Radio Network Optimization. 2000. En las actas del Congreso sobre Computación Evolutiva de 2000, Vol. 1, pp. 317-324.

[8] E. Alba and F. Chicano. On the Behavior of Parallel Genetic Algorithms for Optimal Placement of Antennae in Telecommunications. 2004. International Journal of Foundations of Computer Science, Vol. 16, pp. 343-359, April 2005.

[9] E. Alba. Evolutionary Algorithms for Optimal Placement of Antennae in Radio Network Design. 2004. International Journal of Foundations of Computer Science, Vol. 7, pp. 168.

- [10] E. Alba and F. Chicano. Evolutionary Algorithms in Telecommunications. 2006. En la 13^a Conferencia Electrotécnica Mediterránea (MELECON 2006), Benalmádena, Málaga.
- [11] A. J. Nebro, E. Alba, G. Molina, F. Chicano, F. Luna and J. J. Durillo. Optimal Antenna Placement Using a New Multi-Objective CHC Algorithm. Conferencia sobre la Computación Genética y Evolutiva (GECCO07), London, UK, pp. 876-883.
- [12] P. Calegari, F. Guidic and D. Wagner. Genetic Approach to Radio Network Optimization for Mobile Systems. 1997. En las actas de la 47^a Conferencia del IEEE/VTS sobre Tecnología Vehicular, Phoenix, pp. 755-759.
- [13] E. Alba, G. Molina and F. Chicano. Optimal Placement of Antennae using Metaheuristics. En la Sexta Conferencia Internacional sobre Métodos Numéricos y Aplicaciones (NM&A 06), LNCS 4310, Borovets, Bulgaria, pp. 214-222.
- [14] Michel Vasquez and Jin-Kao Hao. A Heuristic Approach for Antenna Positioning in Cellular Networks. 2000. Journal of Heuristics, Vol. 13, pp. 243-263.
- [15] S. Priem Mendes, J. A. Gómez Pulido, M. A. Vega Rodríguez, M. D. Jaraíz Simón and J. M. Sánchez Pérez. A Differential Evolution Based Algorithm to Optimize the Radio Network Design Problem. 2006. En las actas de la 2^a Conferencia Internacional del IEEE sobre e-Science and Grid Computation. (E-SCIENCE), pp. 119.
- [16] S.P. Mendes, P. Domínguez, D. Pereira, R. Vale, J. A. Gomez-Pulido, L. Moura Silva, A. Vega Rodríguez and J. M. Sánchez Pérez. Omni-directional RND Optimisation using Differential Evolution: In-depth Analysis via High Throughput Computing. 2007. En el Taller de Vida Artificial y Algoritmos Evolutivos (ALEA) - 13^a Conferencia en Inteligencia Artificial Portuguesa, Guimarães, Portugal.
- [17] S.P. Mendes, J. A. Gomez-Pulido, E. Alba, G. Molina, A. Vega Rodríguez and J. D. Vega Pérez. Using Omnidirectional BTS and Different Evolutionary Approaches to Solve the RND Problem. 2007. Computer Systems Aided Theory, pp. 853-860.
- [18] E. Alba and F. Chicano. Ant Colony Optimization for Model Checking. 2007. En la 11^a Conferencia Internacional sobre Teoría de Sistemas Asistidos Computacionales (EUROCAST 2007), LNCS 4739, Gran Canaria, España, pp. 523-530.

- [19] J.A. Sharkey. Automated Radio Network Design Using Ant Colony Optimization. 2008. Universidad de Montana.
- [20] P. Calégari, F. Guidec, P. Kuonen, D. Kobler. Parallel island-based genetic algorithm for radio network design. 1997. Journal of Parallel and Distributed Computing, Vol.47, pp. 86-90.
- [21] R. Lin and M. Gerla. Adaptive Clustering for Mobile Wireless Networks. 1997. IEEE Journal on Selected Areas in Communications, Vol. 15, No. 7, pp. 1265-1275.
- [22] U. Ehrenberger and K. Leibnitz. Impact of Clustered Traffic Distribution in CDMA Radio Network Planning. 1999. Telecommunication Systems, Vol. 15, No. 1-2, pp. 3-20.
- [23] P. Gawrysiak and M. Okoniewski. Applying Data Mining Methods for Cellular Radio Network Planning. 2000. En las actas del Simposio IIS'2000 sobre Sistemas de Información Inteligentes, pp. 87-98.
- [24] J. A. Gómez, M. A. Vega, David Vega and J. M. Sánchez. Desktop Grid Computing with BOINC and its use for Solving the RND Telecommunication Problem. 2007. En las actas de la Conferencia Española sobre e-Science Grid Computing, Ed.: Ciemat, Madrid, pp. 1-10.
- [25] A. Gamst,, E.-G. Zinn, R. Beck and R. Simon. Cellular Radio Network Planning. 1986 IEEE Aerospace and Electronic Systems Magazine, pp. 8-11.
- [26] Aarts, E. and J. Korst. Simulated annealing and boltzmann machines. 1990. Chichester: John Wiley & Sons.
- [27] G. Tongcheng and M. Chundi. Radio network design using coarsegrained parallel genetic algorithms with different neighbor topology. 2002. En las actas del 4^a Congreso Mundial sobre Control Inteligente y Automatización, Vol. 3, pp-1840-1843.
- [28] M. Dorigo, V. Maniezzo and A. Coloni. The Ant System: Optimization by a Colony of Cooperation Agents. 1996. IEEE Transactions on Systems, Man, and Cybernetics-Part B, Vol. 26, pp. 29-41.